

Jesús Asín Lafuente

# Modelos para la precipitación diaria en el marco de los modelos lineales generalizados

Departamento  
Métodos Estadísticos

Director/es  
Abaurrea León, Jesús

<http://zaguan.unizar.es/collection/Tesis>



**Universidad**  
Zaragoza

Tesis Doctoral

# MODELOS PARA LA PRECIPITACIÓN DIARIA EN EL MARCO DE LOS MODELOS LINEALES GENERALIZADOS

Autor

Jesús Asín Lafuente

Director/es

Abaurrea León, Jesús

**UNIVERSIDAD DE ZARAGOZA**

Métodos Estadísticos

2003



# Modelos para la precipitación diaria en el marco de los modelos lineales generalizados

Jesús ASÍN LAFUENTE

Memoria presentada  
para optar al grado de Doctor

Departamento de Métodos Estadísticos  
Universidad de Zaragoza

## Agradecimientos

Esta memoria ha sido realizada en el Dpto. de Métodos Estadísticos a cuyos componentes, sobre todo al personal de la Facultad de Ciencias y del Centro Politécnico Superior, debo agradecer la posibilidad que me han ofrecido de utilizar todas las herramientas necesarias para llevarla a cabo. Debo agradecer también a Jesús Abaurrea, director de la tesis, las horas de trabajo que me ha dedicado.

Para la obtención de los datos ha sido esencial la colaboración del Instituto Nacional de Meteorología, tanto de sus servicios centrales que han proporcionado los datos de los radiosondeos del aeropuerto de Zaragoza y los del modelo HIRLAM, como de su centro territorial en Zaragoza, donde han gestionado con rapidez las peticiones a esos servicios centrales, han proporcionado las series de variables medidas en observatorios de calidad de la cuenca del Ebro y, sobre todo, me han ayudado con sus conocimientos sobre Meteorología y Climatología. Debo agradecer especialmente las sesiones de trabajo con Evelio Álvarez y José Manuel Molina.

Agradezco la ayuda, de muy diferente tipo, que me han prestado mis amigos. Lola Berrade y Germán Badía han hecho lo posible para que mi docencia en Ingenieros no fuera un inconveniente en el avance de mi tesis. Carmen Sangüesa y Jorge Ojeda han soportado, sin ninguna queja, las molestias que les ha provocado mi presencia en su despacho durante años. Carmen Galé, a partir de su revisión de la memoria, me ha ayudado para hacerla más comprensible a los lectores. Todos ellos, junto con José Luis Pelegrín, Pilar Gargallo, Mariano Lázaro, Carlos Valero y muchos otros, a los que pido disculpas por no citar sus nombres, me han animado en todo momento, colaborando a que este trabajo fuera posible.

Con mi familia he contraído una deuda que no puedo pagar con un agradecimiento. Me han respaldado en todo momento más allá de lo que debían hacerlo y sin exigirme sus derechos, que son mis obligaciones.

Gracias a todos.

Jesús Asín

# Índice General

Introducción	xxix
<b>1 Modelos de lluvia. Modelos lineales generalizados</b>	<b>1</b>
1.1 Introducción	1
1.2 Revisión de modelos estocásticos de precipitación diaria	4
1.2.1 Modelos de ocurrencia de lluvia diaria	5
1.2.2 Modelos de cantidad de lluvia	7
1.2.3 Modelización de la lluvia observada	9
1.2.4 Modelos en tiempo continuo	9
1.2.5 Modelos espacio-temporales	10
1.3 El marco de los modelos lineales generalizados	11
1.3.1 Modelos condicionales	14
1.3.2 Modelos marginales	14
1.3.3 Modelos de efectos aleatorios	16
<b>2 Validación y control de la bondad de ajuste de los modelos de ocurrencia</b>	<b>19</b>
2.1 Introducción	19
2.2 Métodos de evaluación de modelos de precipitación diaria	20
2.3 Propuesta de evaluación de los modelos de ocurrencia de lluvia	22
2.3.1 Métodos que usan las probabilidades ajustadas	23
2.3.2 Métodos que utilizan simulación	27
<b>3 Modelos condicionales</b>	<b>31</b>
3.1 Introducción	31
3.2 Observatorios analizados	32
3.3 Modelos de cadena de Markov para la ocurrencia de precipitación	38
3.3.1 Esquema y criterios seguidos en el proceso de ajuste del modelo de ocurrencia	41
3.4 Modelos para la ocurrencia de precipitación en el observatorio de Tortosa	46

3.4.1	Modelos ajustados . . . . .	46
3.4.2	Bondad de ajuste . . . . .	48
3.4.3	Distribución de la longitud de racha . . . . .	50
3.4.4	Comportamiento en el periodo de validación . . . . .	57
3.5	Modelos para la ocurrencia de precipitación en el observatorio de Reinosa . . . . .	60
3.5.1	Modelos ajustados . . . . .	60
3.5.2	Crítica de los modelos ajustados . . . . .	64
3.5.3	Distribución de la longitud de racha . . . . .	65
3.5.4	Comportamiento en el periodo de validación . . . . .	66
3.5.5	Análisis de homogeneidad en el periodo 1985-1994 . . . . .	67
3.6	Modelos para la ocurrencia de precipitación en el observatorio de Agoncillo . . . . .	72
3.6.1	Modelos ajustados . . . . .	74
3.6.2	Crítica de los modelos ajustados . . . . .	76
3.6.3	Distribución de la longitud de racha . . . . .	78
3.6.4	Comportamiento en el periodo de validación . . . . .	80
3.7	Modelos para la ocurrencia de precipitación en el observatorio de Zaragoza . . . . .	82
3.7.1	Datos disponibles . . . . .	82
3.7.2	Modelos ajustados . . . . .	89
3.7.3	Bondad de ajuste . . . . .	92
3.7.4	Distribución de la longitud de racha . . . . .	97
3.7.5	Comportamiento en el periodo de validación . . . . .	101
3.8	Conclusiones sobre la modelización de ocurrencia . . . . .	105
3.8.1	Conclusiones sobre el proceso de modelización . . . . .	105
3.8.2	Comparación entre los resultados obtenidos . . . . .	106
3.9	Modelos para la cantidad de precipitación diaria . . . . .	118
3.9.1	Distribución e hipótesis de independencia . . . . .	118
3.9.2	Estimación de los modelos Gamma . . . . .	120
3.9.3	Métodos para la evaluación de los modelos . . . . .	121
3.10	Modelos de cantidad ajustados . . . . .	123
3.10.1	Modelo de cantidad en Reinosa . . . . .	123
3.10.2	Modelo de cantidad en Tortosa . . . . .	128
3.10.3	Modelo de cantidad en Agoncillo . . . . .	134
3.10.4	Modelos de cantidad en Zaragoza . . . . .	138
3.10.5	Conclusiones . . . . .	148
3.11	Líneas abiertas de investigación . . . . .	159

<b>4</b>	<b>Modelos condicionales de previsión</b>	<b>161</b>
4.1	Introducción . . . . .	161
4.2	La predicción de la precipitación . . . . .	162
4.2.1	La predicción en el INM . . . . .	162
4.2.2	Métodos estadísticos de predicción . . . . .	166
4.3	Modelos de previsión de la precipitación . . . . .	168
4.3.1	Modelo de previsión de ocurrencia . . . . .	168
4.3.2	Modelos de previsión de ocurrencia por épocas del año . . . . .	173
4.3.3	Modelos de previsión de cantidad . . . . .	188
4.4	Predicción de la precipitación mediante el modelo HIRLAM y comparación con los resultados del modelo estadístico . . . . .	190
4.4.1	Introducción . . . . .	190
4.4.2	Análisis de las predicciones de HIRLAM en Zaragoza . . . . .	190
4.4.3	Comparación entre las previsiones de ocurrencia del modelo estadístico y las procedentes de HIRLAM . . . . .	199
4.4.4	Conclusiones . . . . .	202
4.5	Conclusiones y líneas futuras de trabajo . . . . .	203
<b>5</b>	<b>Downscaling estadístico de la precipitación diaria. Proyec- ciones del cambio climático en el área de Zaragoza</b>	<b>205</b>
5.1	Introducción . . . . .	205
5.2	El estudio del cambio climático . . . . .	206
5.3	Modelos estadísticos de downscaling . . . . .	209
5.3.1	Revisión de métodos de downscaling de la precipitación diaria . . . . .	209
5.3.2	Hipótesis y crítica de los modelos estadísticos de down- scaling . . . . .	213
5.4	Disponibilidad de datos diarios generados por los modelos de circulación general . . . . .	215
5.5	Método de downscaling propuesto . . . . .	219
5.6	Datos extraídos de CGCM1 y comparación con el clima ob- servado . . . . .	221
5.6.1	Análisis comparativo de las variables observadas en Za- ragoza y simuladas por el modelo . . . . .	223
5.7	Modelo <i>Down1</i> . . . . .	258
5.7.1	Modelo de ocurrencia de <i>Down1</i> . . . . .	259
5.7.2	Modelo de cantidad de <i>Down1</i> . . . . .	262
5.7.3	Simulación del modelo <i>Down1</i> utilizando los datos ob- servados . . . . .	264
5.8	Simulación de <i>Down1</i> con las covariables generadas por CGCM1 para 1990-2000 . . . . .	267

5.8.1	Comportamiento del modelo de ocurrencia . . . . .	267
5.8.2	Cantidad de lluvia en un día húmedo . . . . .	269
5.8.3	Régimen de precipitación . . . . .	271
5.9	Downscaling con un modelo de lluvia alternativo . . . . .	273
5.9.1	Identificación de las causas que provocan los problemas de <i>Down1</i> en el downscaling . . . . .	273
5.9.2	Modelo <i>Down2</i> . . . . .	277
5.9.3	Downscaling con los datos generados por CGCM1 para el periodo 1990-2000 . . . . .	281
5.10	Proyección de la precipitación diaria en Zaragoza en el periodo 2090-2100 . . . . .	286
5.10.1	Análisis comparativo de los resultados de CGCM1 para los periodos 1990-2000 y 2090-2100 . . . . .	286
5.10.2	Downscaling con el modelo <i>Down2</i> usando los datos de CGCM1 para el periodo 2090-2100 . . . . .	293
5.10.3	Downscaling de la precipitación con otros modelos . . .	297
5.11	Conclusiones y líneas de investigación abiertas . . . . .	302
5.11.1	Conclusiones sobre el procedimiento de downscaling propuesto . . . . .	302
5.11.2	Líneas de investigación abiertas . . . . .	305
<b>Bibliografía</b>		<b>311</b>
<b>A Tablas de los modelos condicionales</b>		<b>1</b>
A.1	Modelos de ocurrencia . . . . .	1
A.1.1	Tortosa . . . . .	2
A.1.2	Reinosa . . . . .	18
A.1.3	Agoncillo . . . . .	37
A.1.4	Zaragoza . . . . .	62
A.2	Modelos de cantidad . . . . .	89
A.2.1	Reinosa . . . . .	89
A.2.2	Tortosa . . . . .	94
A.2.3	Agoncillo . . . . .	99
A.2.4	Zaragoza . . . . .	104
<b>B Tablas de los modelos para la previsión en Zaragoza</b>		<b>113</b>
B.1	Tablas de los modelos para la previsión estadística . . . . .	113
B.2	Tablas para la comparación con las previsiones HIRLAM . . .	125

<b>C</b>	<b>Tablas del downscaling</b>	<b>133</b>
C.1	Comparación de los datos observados y simulados por CGCM1	133
C.2	Downscaling con el modelo <i>Down1</i> . . . . .	145
C.3	Búsqueda de un modelo estadístico para el downscaling . . . . .	158
C.4	Downscaling con el modelo <i>Down2</i> . . . . .	166
C.5	Downscaling para el periodo 2090-2100 . . . . .	179



# Índice de Tablas

3.1	Posición geográfica de los observatorios y periodo de registro utilizado. . . . .	32
3.2	Valores medios de la precipitación acumulada en el periodo normal 1961-1990, Almarza y otros (2000) [13]. . . . .	33
3.3	Frecuencia de grandes precipitaciones en los observatorios estudiados.	36
3.4	Matriz de probabilidades de transición del modelo <i>CM hom-T</i> . . . . .	52
3.5	Probabilidades estacionarias del modelo <i>CM hom-T</i> . . . . .	53
3.6	Modelo estacional de ocurrencia ajustado en Reinosa en los periodos 1985-1994 y 1960-1975, que utiliza como ‘offset’ el predictor lineal de <i>CM est-R</i> estimado en 1912-1959. . . . .	70
3.7	Modelo de ocurrencia con temperaturas ajustado en Reinosa en 1985-1994 que utiliza como ‘offset’ el predictor lineal de <i>CM temp-R</i> estimado en el periodo 1912-1959. . . . .	70
3.8	Medidas de bondad de ajuste de los modelos markovianos ajustados en Agoncillo (1978-1992). . . . .	76
3.9	Porcentaje de días bien clasificados por los modelos ajustados en Agoncillo (1978-1992). . . . .	76
3.10	Medidas de bondad de ajuste basadas en la frecuencia mensual de días con precipitación para los modelos ajustados en Agoncillo (1978-1992). . . . .	77
3.11	Estadísticos obtenidos a partir de la simulación de las cadenas de Markov ajustadas en Agoncillo (1978-1992). . . . .	78
3.12	Estadísticos de la distribución de la longitud de racha observada y obtenida con los modelos ajustados en Agoncillo (1978-1992). . . . .	80
3.13	Medidas de bondad de ajuste de los cinco modelos estudiados en Agoncillo, en el periodo de validación (1993-1997). . . . .	81
3.14	Variables utilizadas en el observatorio de Zaragoza-aeropuerto. . . . .	84
3.15	Medidas de bondad de ajuste para los modelos de ocurrencia ajustados en Zaragoza (1990-1997). . . . .	92
3.16	Porcentaje de días bien clasificados por los modelos de ocurrencia ajustados en Zaragoza (1990-1997). . . . .	93

3.17	Medidas de bondad de ajuste basadas en la frecuencia mensual de días con precipitación para los modelos ajustados en Zaragoza (1990-1997). . . . .	94
3.18	Medidas de bondad de ajuste, por estaciones, de cinco modelos seleccionados, Zaragoza (1990-1997). . . . .	96
3.19	Estadísticos relativos a la serie de ocurrencia observados y estimados mediante simulación, Zaragoza (1990-1997). . . . .	98
3.20	Estadísticos de la distribución de la longitud de racha, observados y obtenidos con distintos modelos, Zaragoza (1990-1997). . . . .	99
3.21	Medidas de bondad de ajuste de las cadenas de Markov ajustadas en Zaragoza sobre el conjunto de validación (1998-2000). . . . .	104
3.22	Coefficientes estimados de los dos primeros retardos en los modelos <i>CM hom</i> y <i>CM est</i> en los cuatro observatorios. . . . .	107
3.23	Medidas de bondad de ajuste de los modelos de ocurrencia ajustados en los cuatro observatorios. . . . .	110
3.24	Porcentaje % <i>NAS</i> obtenido en distintos modelos ajustados en los cuatro observatorios. . . . .	114
3.25	Medidas de bondad de ajuste basadas en la frecuencia de días con precipitación, por meses, para los modelos ajustados en los cuatro observatorios. . . . .	115
3.26	Meses en los que se rechaza al 5% la igualdad de distribución de la longitud de racha observada y la obtenida a partir de los modelos ajustados en los cuatro observatorios. . . . .	116
3.27	Valores medios de la cantidad acumulada estacional, observados y ajustados por el modelo en Tortosa (1942-1981). . . . .	132
3.28	Porcentaje de variabilidad explicada, global y estacionalmente, en los conjuntos de estimación y validación. . . . .	153
3.29	Porcentaje de variabilidad explicada, global y estacionalmente, en los conjuntos de estimación y validación, con todos los datos y prescindiendo del dato más discrepante. . . . .	155
3.30	Medidas de bondad de ajuste basadas en la media anual de la cantidad diaria para los modelos ajustados en los cuatro observatorios. . . . .	156
3.31	Medidas de bondad de ajuste basadas en la media de la cantidad diaria, por meses, para los modelos ajustados en los cuatro observatorios. . . . .	158
4.1	Porcentajes de días bien predichos por el modelo para los meses fríos. . . . .	176
4.2	Porcentajes de días bien predichos por los dos modelos de previsión en los días del periodo templado. . . . .	178
4.3	Porcentajes de días bien predichos por los dos modelos de previsión en los días del periodo cálido. . . . .	181

4.4	Comparación de los términos significativos en los modelos de previsión de ocurrencia. . . . .	184
4.5	Porcentajes de variabilidad explicada por los distintos modelos de previsión. . . . .	184
4.6	Porcentajes de días bien predichos por los modelos de previsión. . . . .	185
5.1	Extracción de información para las 9 celdas seleccionadas. . . . .	222
5.2	Variables extraídas de CGCM1. . . . .	222
5.3	Resultados de los tests que comparan la distribución de los datos diarios observados y simulados por CGCM1 para 1990-2000. . . . .	242
5.4	Resultados del test KS para comparar la distribución mensual de los datos diarios observados y de los simulados por CGCM1 para 1990-2000. . . . .	245
5.5	Resultados del test F para comparar por meses la varianza de los datos diarios observados y de los simulados por CGCM1 para 1990-2000. . . . .	246
5.6	Número de tests independientes con los que se aceptaría la hipótesis nula global, con nivel de significación $\alpha^G$ , dada esa frecuencia relativa de rechazo en los tests locales, con nivel de significación $\alpha$ . . . . .	247
5.7	Resultado del test global para evaluar la reproducción correcta de variables y anomalías. . . . .	248
5.8	Autocorrelaciones de orden 1 y 2 de las variables observadas y generadas por CGCM1 para el periodo 1990-2000. . . . .	250
5.9	Matriz de correlación de las variables consideradas por CGCM1 para el periodo 1990-2000. . . . .	254
5.10	Matriz de correlación de las anomalías de las variables observadas y generadas por CGCM1 para el periodo 1990-2000. . . . .	255
5.11	Régimen de precipitación observado y obtenido de la simulación del modelo <i>Down1</i> , usando los datos observados en el periodo 1990-2000. . . . .	265
5.12	Frecuencia observada y probabilidades de ocurrencia ajustadas con <i>Down1</i> , a) usando los datos observados y b) los simulados por CGCM1, periodo 1990-2000. . . . .	267
5.13	Estadísticos relativos a la ocurrencia observada y simulada por <i>Down1</i> usando los datos observados y los generados por CGCM1, periodo 1990-2000. . . . .	268
5.14	Régimen de precipitación observado y proyectado por <i>Down1</i> a partir de los datos observados y generados por CGCM1 para 1990-2000. . . . .	272
5.15	Régimen de precipitación observado y obtenido mediante simulación con <i>Down1</i> , usando los datos generados por el GCM para el periodo 1990-2000. . . . .	272

5.16	Clasificación de las covariables problemáticas de <i>Down1</i> , atendiendo a su posible uso en la construcción del modelo <i>Down2</i> . . . . .	275
5.17	Régimen de precipitación observado y proyectado por <i>Down2</i> a partir de los datos observados y de los generados por CGCM1 para 1990-2000. . . . .	276
5.18	Régimen de precipitación observado y obtenido en la simulación del modelo <i>Down2</i> utilizando los datos generados por CGCM1 para el periodo 1990-2000. . . . .	283
5.19	Momentos y cuartiles de las variables simuladas por CGCM1 en los periodos 1990-2000 y 2090-2100. . . . .	288
5.20	Características de la frecuencia de lluvia observada y de las probabilidades ajustadas por <i>Down2</i> , con los datos observados y los generados por CGCM1 para el periodo 2090-2100. . . . .	293
5.21	Régimen de precipitación observado y obtenido en la simulación del modelo <i>Down2</i> utilizando los datos generados por CGCM1 para 2090-2100. . . . .	296
5.22	Régimen de precipitación observado y obtenido en el downscaling con <i>Down1</i> a partir de los datos de CGCM1 para el periodo 2090-2100. . . . .	299
5.23	Régimen de precipitación observado y ajustado por el modelo de lluvia que no utiliza información de humedad, usando los datos observados y los generados por CGCM1 para los periodos 1990-2000 y 2090-2100. . . . .	301
5.24	Anomalías y variables seleccionadas como covariables candidatas en los modelos <i>Down1</i> y <i>Down2</i> y según otros criterios. . . . .	306
A.1	Modelos markovianos homogéneo y estacional para el proceso de ocurrencia en Tortosa. . . . .	3
A.2	Modelo de cadena de Markov con información de temperatura ajustado en Tortosa. . . . .	4
A.3	Medidas de bondad de ajuste de la cadena de Markov homogénea, Tortosa (1942-1981). . . . .	5
A.4	Medidas de bondad de ajuste de la cadena de Markov estacional, Tortosa (1942-1981). . . . .	6
A.5	Medidas de bondad de ajuste de la cadena de Markov con información de temperatura, Tortosa (1942-1981). . . . .	7
A.6	Distribuciones de las longitudes de racha observada y teórica según <i>CM hom</i> , Tortosa (1942-1981). . . . .	8
A.7	Distribuciones de las longitudes de racha observada y teórica según <i>CM hom</i> , por meses, Tortosa (1942-1981). . . . .	9

A.8	Percentiles de las longitudes de racha observada y simulada por <i>CM est</i> , Tortosa (1942-1981).	10
A.9	Percentiles de las longitudes de racha observada y simulada por <i>CM temp</i> , Tortosa (1942-1981).	11
A.10	Medidas de bondad de ajuste de <i>CM hom</i> , Tortosa periodo de validación (1982-1991).	12
A.11	Medidas de bondad de ajuste de <i>CM est</i> , Tortosa periodo de validación (1982-1991).	13
A.12	Medidas de bondad de ajuste para <i>CM temp</i> , Tortosa periodo de validación (1982-1991).	14
A.13	Distribuciones de las longitudes de racha, observada y teórica según <i>CM hom</i> , por meses, Tortosa (1982-1991).	15
A.14	Percentiles de las longitudes de racha observada y simulada por <i>CM est</i> , Tortosa (1982-1991).	16
A.15	Percentiles de las longitudes de racha observada y simulada por <i>CM temp</i> , Tortosa (1982-1991).	17
A.16	Modelos markovianos homogéneo y estacional para el proceso de ocurrencia en Reinoso.	19
A.17	Modelo de cadena de Markov con información de temperatura ajustado en Reinoso.	20
A.18	Medidas de bondad de ajuste de la cadena de Markov homogénea, Reinoso (1912-1959).	21
A.19	Medidas de bondad de ajuste de la cadena de Markov estacional, Reinoso (1912-1959).	22
A.20	Medidas de bondad de ajuste de la cadena de Markov con información de temperatura, Reinoso (1912-1959).	23
A.21	Distribución de las longitudes de racha observada y teórica según <i>CM hom</i> , Reinoso (1912-1959).	24
A.22	Distribución de la longitud de racha, observada y teórica según <i>CM hom</i> , por meses, Reinoso (1912-1959).	25
A.23	Percentiles de las longitudes de racha observada y simulada por <i>CM est</i> , Reinoso (1912-1959).	26
A.24	Percentiles de las longitudes de racha observada y simulada por <i>CM temp</i> , Reinoso (1912-1959).	27
A.25	Medidas de bondad de ajuste de <i>CM hom</i> , Reinoso, periodo de validación (1960-1975).	28
A.26	Medidas de bondad de ajuste de <i>CM est</i> , Reinoso, periodo de validación (1960-1975).	29
A.27	Medidas de bondad de ajuste de <i>CM temp</i> , Reinoso, periodo de validación (1960-1975).	30

A.28	Distribuciones de las longitudes de racha observada y teórica según <i>CM hom</i> , por meses, Reinososa (1960-1975). . . . .	31
A.29	Percentiles de las longitudes de racha observada y simulada por <i>CM est</i> , Reinososa (1960-1975). . . . .	32
A.30	Percentiles de las longitudes de racha observada y simulada por <i>CM temp</i> , Reinososa (1960-1975). . . . .	33
A.31	Medidas de bondad de ajuste de <i>CM hom</i> , Reinososa (1985-1994). . . . .	34
A.32	Medidas de bondad de ajuste de <i>CM est</i> , Reinososa (1985-1994). . . . .	35
A.33	Medidas de bondad de ajuste de <i>CM temp</i> , Reinososa (1985-1994). . . . .	36
A.34	Modelos markovianos homogéneo, estacional y con información de temperatura para el proceso de ocurrencia en Agoncillo. . . . .	38
A.35	Modelos de cadena de Markov con información de presión ajustados en Agoncillo. . . . .	39
A.36	Medidas de bondad de ajuste de la cadena de Markov homogénea, Agoncillo (1978-1992). . . . .	40
A.37	Medidas de bondad de ajuste de la cadena de Markov estacional, Agoncillo (1978-1992). . . . .	41
A.38	Medidas de bondad de ajuste de la cadena de Markov con información de temperatura, Agoncillo (1978-1992). . . . .	42
A.39	Medidas de bondad de ajuste de la cadena de Markov con presiones atmosféricas, Agoncillo (1978-1992). . . . .	43
A.40	Medidas de bondad de ajuste de la cadena de Markov con temperaturas y presiones atmosféricas, Agoncillo (1978-1992). . . . .	44
A.41	Distribuciones de las longitudes de racha observada y teórica según <i>CM hom</i> , Agoncillo (1978-1992). . . . .	45
A.42	Distribuciones de las longitudes de racha, observada y teórica según <i>CM hom</i> , por meses, Agoncillo (1978-1992). . . . .	46
A.43	Percentiles de las longitudes de racha observada y simulada por <i>CM est</i> , Agoncillo (1978-1992). . . . .	47
A.44	Percentiles de las longitudes de racha observada y simulada por <i>CM temp</i> , Agoncillo (1978-1992). . . . .	48
A.45	Percentiles de las longitudes de racha observada y simulada por <i>CM pres</i> , Agoncillo (1978-1992). . . . .	49
A.46	Percentiles de las longitudes de racha observada y simulada por <i>CM temp y pres</i> , Agoncillo (1978-1992). . . . .	50
A.47	Medidas de bondad de ajuste de <i>CM hom</i> , Agoncillo periodo de validación (1993-1997). . . . .	51
A.48	Medidas de bondad de ajuste de <i>CM est</i> , Agoncillo, periodo de validación (1993-1997). . . . .	52
A.49	Medidas de bondad de ajuste de <i>CM temp</i> , Agoncillo, periodo de validación (1993-1997). . . . .	53

A.50	Medidas de bondad de ajuste de <i>CM pres</i> , Agoncillo, periodo de validación (1993-1997). . . . .	54
A.51	Medidas de bondad de ajuste de <i>CM temp y pres</i> , Agoncillo, periodo de validación (1993-1997). . . . .	55
A.52	Distribuciones de las longitudes de racha observada y teórica según <i>CM hom</i> , Agoncillo (1993-1997). . . . .	56
A.53	Distribuciones de las longitudes de racha, observada y teórica según <i>CM hom</i> , por meses, Agoncillo (1993-1997). . . . .	57
A.54	Percentiles de las longitudes de racha observada y simulada por <i>CM est</i> , Agoncillo (1993-1997). . . . .	58
A.55	Percentiles de las longitudes de racha observada y simulada por <i>CM temp</i> , Agoncillo (1993-1997). . . . .	59
A.56	Percentiles de las longitudes de racha observada y simulada por <i>CM pres</i> , Agoncillo (1993-1997). . . . .	60
A.57	Percentiles de las longitudes de racha observada y simulada por <i>CM temp y pres</i> , Agoncillo (1993-1997). . . . .	61
A.58	Modelos de cadena de Markov homogéneo, estacional y con información de temperaturas para el proceso de ocurrencia en Zaragoza.	63
A.59	Modelos de cadena de Markov con variables de superficie y con altura, temperatura y punto de rocío del radiosondeo de las 12h para el proceso de ocurrencia en Zaragoza. . . . .	64
A.60	Modelos de cadena de Markov con información de los radiosondeos de las 0 y las 12h para el proceso de ocurrencia en Zaragoza. . . . .	65
A.61	Cadena de Markov con información de superficie y de los radiosondeos incluso del día $t + 1$ para el proceso de ocurrencia en Zaragoza.	66
A.62	Medidas de bondad de ajuste de la cadena de Markov homogénea, Zaragoza (1990-1997). . . . .	67
A.63	Medidas de bondad de ajuste de la cadena de Markov estacional, Zaragoza (1990-1997). . . . .	68
A.64	Medidas de bondad de ajuste de la cadena de Markov con temperaturas máximas y mínimas, Zaragoza (1990-1997). . . . .	69
A.65	Medidas de bondad de ajuste de la cadena de Markov con temperaturas y presión en superficie, Zaragoza (1990-1997). . . . .	70
A.66	Medidas de bondad de ajuste de la cadena de Markov con información de superficie y de radiosondeos, Zaragoza (1990-1997). . . . .	71
A.67	Distribuciones de las longitudes de racha observada y teórica según <i>CM hom</i> , Zaragoza (1990-1997). . . . .	72
A.68	Distribuciones de las longitudes de racha, observada y teórica según <i>CM hom</i> , por meses, Zaragoza (1990-1997). . . . .	73
A.69	Percentiles de las longitudes de racha observada y simulada por <i>CM est</i> , Zaragoza (1990-1997). . . . .	74

A.70	Percentiles de las longitudes de racha observada y simulada por <i>CM temp</i> , Zaragoza (1990-1997). . . . .	75
A.71	Percentiles de las longitudes de racha observada y simulada por <i>CM superficie</i> , Zaragoza (1990-1997). . . . .	76
A.72	Percentiles de las longitudes de racha observada y simulada por <i>CM sondeos</i> , Zaragoza (1990-1997). . . . .	77
A.73	Medidas de bondad de ajuste de <i>CM hom</i> , Zaragoza, periodo de validación (1998-2000). . . . .	78
A.74	Medidas de bondad de ajuste de <i>CM est</i> , Zaragoza, periodo de validación (1998-2000). . . . .	79
A.75	Medidas de bondad de ajuste de <i>CM temp</i> , Zaragoza, periodo de validación (1998-2000). . . . .	80
A.76	Medidas de bondad de ajuste de <i>CM superficie</i> , Zaragoza, periodo de validación (1998-2000). . . . .	81
A.77	Medidas de bondad de ajuste de <i>CM sondeos</i> , Zaragoza, periodo de validación (1998-2000). . . . .	82
A.78	Distribuciones de las longitudes de racha observada y teórica según <i>CM hom</i> , Zaragoza (1998-2000). . . . .	83
A.79	Distribuciones de las longitudes de racha, observada y teórica según <i>CM hom</i> , por meses, Zaragoza (1998-2000). . . . .	84
A.80	Percentiles de las longitudes de racha observada y simulada por <i>CM est</i> , Zaragoza (1998-2000). . . . .	85
A.81	Percentiles de las longitudes de racha observada y simulada por <i>CM temp</i> , Zaragoza (1998-2000). . . . .	86
A.82	Percentiles de las longitudes de racha observada y simulada por <i>CM superficie</i> , Zaragoza (1998-2000). . . . .	87
A.83	Percentiles de las longitudes de racha observada y simulada por <i>CM sondeos</i> , Zaragoza (1998-2000). . . . .	88
A.84	Modelo para la cantidad de precipitación positiva en Reinososa (1912-1959). . . . .	89
A.85	Medidas de bondad de ajuste para el modelo de cantidad en Reinososa (1912-1959). . . . .	90
A.86	Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Reinososa (1912-1959). . . . .	91
A.87	Medidas de bondad de ajuste para el modelo de cantidad en Reinososa, periodo de validación (1960-1975). . . . .	92
A.88	Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Reinososa, periodo de validación (1960-1975). . . . .	93
A.89	Modelo para la cantidad de precipitación diaria, Tortosa (1942-1981). . . . .	94

A.90	Medidas de bondad de ajuste para el modelo de cantidad, Tortosa (1942-1981). . . . .	95
A.91	Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Tortosa (1942-1981). . . . .	96
A.92	Medidas de bondad de ajuste para el modelo de cantidad en Tortosa, periodo de validación (1982-1991). . . . .	97
A.93	Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Tortosa, periodo de validación (1982-1991). . . . .	98
A.94	Modelo para la cantidad de precipitación diaria, Agoncillo (1978-1992). . . . .	99
A.95	Medidas de bondad de ajuste para el modelo de cantidad, Agoncillo (1978-1992). . . . .	100
A.96	Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Agoncillo (1978-1992). . . . .	101
A.97	Medidas de bondad de ajuste para el modelo de cantidad en Agoncillo, periodo de validación (1993-1997). . . . .	102
A.98	Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Agoncillo, periodo de validación (1993-1997). . . . .	103
A.99	Modelo para la cantidad de precipitación diaria con información de superficie, Zaragoza (1990-1997). . . . .	104
A.100	Medidas de bondad de ajuste para el modelo de cantidad con información de superficie, Zaragoza (1990-1997). . . . .	105
A.101	Medidas de bondad de ajuste para el modelo de cantidad con información de superficie, Zaragoza, periodo de validación (1998-2000). . . . .	106
A.102	Modelo para la cantidad de precipitación diaria con información del radiosondeo, Zaragoza (1990-1997). . . . .	107
A.103	Medidas de bondad de ajuste del modelo de cantidad con información del radiosondeo, Zaragoza (1990-1997). . . . .	108
A.104	Percentiles de las cantidades observadas y simuladas por el modelo de cantidad con información del radiosondeo, Zaragoza (1990-1997). . . . .	109
A.105	Medidas de bondad de ajuste para el modelo de cantidad con información del radiosondeo, Zaragoza, periodo de validación (1998-2000). . . . .	110
A.106	Percentiles de las cantidades observadas y simuladas por el modelo de cantidad con información del radiosondeo, Zaragoza, periodo de validación (1998-2000). . . . .	111
B.1	Modelo de previsión de ocurrencia a las 18h del día previo. . . . .	114
B.2	Medidas de bondad de ajuste del modelo de previsión de ocurrencia para todo el año (1990-1997). . . . .	115
B.3	Medidas de bondad de ajuste del modelo de previsión de ocurrencia para todo el año, periodo de validación 1998-2000. . . . .	116

B.4	Modelo de previsión de ocurrencia a las 18h del día previo, para los meses fríos. . . . .	117
B.5	Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses fríos (1990-1997). . . . .	117
B.6	Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses fríos, periodo de validación 1998-2000. . . . .	118
B.7	Modelo de previsión de ocurrencia a las 18h del día previo, para los meses templados. . . . .	118
B.8	Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses templados (1990-1997). . . . .	119
B.9	Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses templados, periodo de validación 1998-2000. . . . .	120
B.10	Modelo de previsión de ocurrencia a las 18h del día previo, para los meses cálidos. . . . .	121
B.11	Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses cálidos (1990-1997). . . . .	121
B.12	Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses cálidos, periodo de validación 1998-2000. . . . .	122
B.13	Modelo de previsión de cantidad a las 18h del día previo. . . . .	123
B.14	Medidas de bondad de ajuste del modelo de previsión para la cantidad en un día con lluvia (1990-1997). . . . .	123
B.15	Medidas de bondad de ajuste del modelo de previsión para la cantidad en un día con lluvia, periodo de validación 1998-2000. . . . .	124
B.16	Características de la lluvia diaria observada y prevista por HIRLAM. . . . .	125
B.17	Características por meses de la lluvia diaria observada y prevista HIRLAM. . . . .	126
B.18	Características por meses de la lluvia diaria observada y prevista HIRLAM. Continuación. . . . .	127
B.19	Comparación entre la ocurrencia de lluvia diaria observada, prevista por el modelo estadístico anual y prevista por HIRLAM (umbral 1dl). . . . .	128
B.20	Comparación entre la ocurrencia de lluvia diaria observada en los meses fríos, prevista por el modelo estadístico anual y prevista por HIRLAM (umbral 1dl). . . . .	128
B.21	Comparación entre la ocurrencia de lluvia diaria observada en los meses templados, prevista por el modelo estadístico específico y prevista por HIRLAM (umbral 1dl). . . . .	129
B.22	Comparación entre la ocurrencia de lluvia diaria observada en los meses cálidos, prevista por los modelos estadísticos y prevista por HIRLAM (umbral 1dl). . . . .	129

B.23	Comparación entre la ocurrencia de lluvia diaria observada, prevista por el modelo estadístico anual y prevista por HIRLAM (umbral 6dl), para los meses fríos. . . . .	130
B.24	Comparación entre la ocurrencia de lluvia diaria observada, prevista por el modelo estadístico específico y prevista por HIRLAM (umbral 13dl), para los meses templados. . . . .	130
B.25	Comparación entre la ocurrencia de lluvia diaria observada, prevista por los modelos estadísticos y prevista por HIRLAM (umbral 19dl), para los meses cálidos. . . . .	131
C.1	Momentos y cuartiles de las variables observadas y generadas para el conjunto del periodo 1990-2000. . . . .	134
C.2	Momentos y cuartiles de las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en Invierno y Primavera. . . . .	135
C.3	Momentos y cuartiles de las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en Verano y Otoño. . . . .	136
C.4	Tests para comparar las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en superficie. . . . .	137
C.5	Tests para comparar las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en la altura del geopotencial 850hPa. . . . .	138
C.6	Tests para comparar las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en la altura del geopotencial 500hPa, y diferencias de temperatura y altura entre ambos geopotenciales. . . . .	139
C.7	Tests para comparar las componentes de viento observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes. . . . .	140
C.8	Tests para comparar las anomalías de las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en superficie. . . . .	141
C.9	Tests para comparar las anomalías de las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en la altura del geopotencial 850hPa. . . . .	142
C.10	Tests para comparar las anomalías de las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en el geopotencial 500hPa, y diferencias de temperatura y altura entre ambos geopotenciales. . . . .	143
C.11	Tests para comparar las anomalías de las componentes de viento observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes. . . . .	144
C.12	Modelo para la ocurrencia de <i>Down</i> 1. . . . .	146

C.13	Medidas de bondad de ajuste del modelo de ocurrencia de <i>Down1</i> (1990-1997). . . . .	147
C.14	Medidas de bondad de ajuste del modelo de ocurrencia de <i>Down1</i> , periodo de validación (1998-2000). . . . .	148
C.15	Percentiles de la longitud de racha seca observada y simulada por el modelo de ocurrencia de <i>Down1</i> , para cada mes, usando los datos observados en Zaragoza, en los periodos de estimación y validación. . . . .	149
C.16	Percentiles de la longitud de racha húmeda observada y simulada por el modelo de ocurrencia de <i>Down1</i> , para cada mes, usando los datos observados en Zaragoza, en los periodos de estimación y validación. . . . .	150
C.17	Modelo de cantidad de <i>Down1</i> . . . . .	151
C.18	Medidas de bondad de ajuste del modelo de cantidad de <i>Down1</i> (1990-1997). . . . .	152
C.19	Medidas de bondad de ajuste del modelo de cantidad de <i>Down1</i> , periodo de validación (1998-2000). . . . .	153
C.20	Percentiles de las cantidades observadas y simuladas por el modelo <i>Down1</i> , usando los datos en los días de lluvia observados en Zaragoza. . . . .	154
C.21	Percentiles de la longitud de racha seca observada y simulada por el modelo <i>Down1</i> , para cada mes, usando los datos observados en Zaragoza y los generados por CGCM1 para el periodo 1990-2000. . . . .	155
C.22	Percentiles de la longitud de racha húmeda observada y simulada por el modelo <i>Down1</i> , para cada mes, usando los datos observados en Zaragoza y los generados por CGCM1 para el periodo 1990-2000. . . . .	156
C.23	Percentiles de las cantidades observadas y simuladas por el modelo <i>Down1</i> , para cada mes, usando los datos observados y los generados por CGCM1 para 1990-2000. . . . .	157
C.24	Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. . . . .	159
C.25	Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación. . . . .	160
C.26	Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación. . . . .	161
C.27	Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación. . . . .	162

C.28 Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación. . . . . 163

C.29 Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación. . . . . 164

C.30 Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación. . . . . 165

C.31 Modelo de ocurrencia de *Down2*. . . . . 167

C.32 Medidas de bondad de ajuste del submodelo de ocurrencia de *Down2* (1990-1997). . . . . 168

C.33 Medidas de bondad de ajuste del submodelo de ocurrencia de *Down2*, periodo de validación (1998-2000). . . . . 169

C.34 Percentiles de la longitud de racha seca observada y simulada por el modelo *Down2–Oc*, para cada mes, usando los datos observados en Zaragoza, en los periodos de estimación y validación. . . . . 170

C.35 Percentiles de la longitud de racha húmeda observada y simulada por el modelo *Down2–Oc*, para cada mes, usando los datos observados en Zaragoza, en los periodos de estimación y validación. 171

C.36 Modelo de cantidad de *Down2*. . . . . 172

C.37 Medidas de bondad de ajuste del submodelo de cantidad de *Down2* (1990-1997). . . . . 173

C.38 Medidas de bondad de ajuste del submodelo de cantidad de *Down2*, periodo de validación (1998-2000). . . . . 174

C.39 Percentiles de las cantidades observadas y simuladas por el modelo *Down2–C*, usando los datos en los días de lluvia observados en Zaragoza. . . . . 175

C.40 Percentiles de la longitud de racha seca observada y simulada por el modelo *Down2*, para cada mes, usando los datos observados en Zaragoza y los generados por CGCM1 para el periodo 1990-2000. . 176

C.41 Percentiles de la longitud de racha húmeda observada y simulada por el modelo *Down2*, para cada mes, usando los datos observados en Zaragoza y los generados por CGCM1 para el periodo 1990-2000. 177

C.42 Percentiles de las cantidades observadas y simuladas por el modelo *Down2*, para cada mes, usando los datos observados y los generados por CGCM1 para 1990-2000. . . . . 178

C.43 Percentiles de las longitudes de rachas secas observadas y simuladas por el modelo *Down2*, para cada mes, usando los datos generados por CGCM1 para el periodo 2090-2100. . . . . 180

C.44	Percentiles de las longitudes de rachas húmedas observadas y simuladas por el modelo <i>Down2</i> , para cada mes, usando los datos generados por CGCM1 para el periodo 2090-2100. . . . .	181
C.45	Percentiles de las cantidades observadas y simuladas por el modelo <i>Down2</i> , para cada mes, usando los datos generados por CGCM1 para el periodo 2090-2100. . . . .	182
C.46	Modelo de ocurrencia que no usa información de humedad. . . . .	183
C.47	Modelo de cantidad que no usa información de humedad. . . . .	183
C.48	Medidas de bondad de ajuste para el modelo de ocurrencia que no usa información de humedad (1990-1997). . . . .	184
C.49	Medidas de bondad de ajuste para el modelo de cantidad que no usa información de humedad (1990-1997). . . . .	185

# Índice de Figuras

3.1	Valores medios de la precipitación acumulada mensual en el periodo 1961-1990, Almarza y otros (2000) [13]. . . . .	34
3.2	Valores suavizados de la frecuencia diaria de ocurrencia de precipitación. . . . .	34
3.3	Valores suavizados de la cantidad media registrada en días con precipitación. . . . .	35
3.4	Mapa de la cuenca del Ebro y regiones con una evolución temporal homogénea de la precipitación anual, Abaurrea y otros (2002) [10].	36
3.5	Probabilidad de lluvia ajustada por <i>CM est</i> en Tortosa en las distintas situaciones de ocurrencia previa. . . . .	47
3.6	Ajuste de <i>CM temp</i> en Tortosa. Izda.: Efecto del rango diario de temperatura ( $10^{-1}$ °C). Dcha.: Idem de la temperatura mínima ( $10^{-1}$ °C). . . . .	48
3.7	Frecuencia mensual de días con precipitación; datos observados y ajustados por <i>CM temp</i> en Tortosa (1942-1981). . . . .	49
3.8	Porcentaje de días con lluvia observado anualmente frente al obtenido utilizando los tres modelos de ocurrencia en Tortosa (1942-1981).	50
3.9	Izda.: Correlograma de la serie de ocurrencia observada en Tortosa (1942-1981). Dcha.: Idem de la serie de residuos del modelo <i>CM temp-T</i> . . . . .	51
3.10	Correlograma de la serie de ocurrencia observada en Tortosa (1942-1981) y valores medios de las autocorrelaciones obtenidas en 20 simulaciones de <i>CM temp</i> . . . . .	55
3.11	Percentiles de la distribución de la longitud de las rachas húmedas: datos observados y simulados a partir de <i>CM temp-T</i> , en Diciembre.	56
3.12	Percentiles de la distribución de la longitud de las rachas húmedas: datos observados y simulados a partir de <i>CM temp-T</i> , en Junio. . .	56
3.13	Comportamiento de <i>CM est-T</i> en el periodo de validación (1982-1991). . . . .	57
3.14	Comportamiento de <i>CM temp-T</i> en el periodo de validación (1982-1991). . . . .	58

3.15	Probabilidades de ocurrencia ajustadas con <i>CM hom*</i> en Reinosa (1912-1959). . . . .	61
3.16	Probabilidades de ocurrencia ajustadas en Reinosa con el modelo <i>CM est.</i> . . . . .	62
3.17	Ajuste de <i>CM temp</i> en Reinosa. Izda.: Efecto del rango de temperatura en el día <i>t</i> . Dcha.: Efecto del rango en el día $t - 1$ . . . . .	63
3.18	Ajuste de <i>CM temp</i> en Reinosa. Efecto de la temperatura mínima. . . . .	63
3.19	Porcentaje observado de días con lluvia en cada año frente al obtenido en el ajuste con los modelos de ocurrencia en Reinosa (1912-1959). . . . .	65
3.20	Comportamiento de <i>CM est</i> en Reinosa en el periodo de validación (1960-1975). . . . .	68
3.21	Comportamiento de <i>CM est</i> en Reinosa (1985-1994). . . . .	69
3.22	Suavizado del valor medio diario de la presión en las horas tipo, Agoncillo (1978-1997). . . . .	73
3.23	Evolución de la diferencia de presión entre medidas consecutivas, Agoncillo (1978-1997). . . . .	73
3.24	Ajuste del modelo <i>CM tempres</i> en Agoncillo. Izda.: Efecto del rango de temperatura. Dcha.: Efecto de la anomalía de presión a las 7 horas. . . . .	75
3.25	Porcentaje anual observado de días con lluvia frente al obtenido con los modelos de ocurrencia en Agoncillo (1978-1992). . . . .	77
3.26	Diagramas de caja por meses de la temperatura mínima en Zaragoza (1990-2000). . . . .	85
3.27	Cambios de presión entre medidas consecutivas en Zaragoza. . . . .	86
3.28	Frecuencia relativa de direcciones de viento en Zaragoza (1990-2000). . . . .	87
3.29	Frecuencia relativa de ocurrencia de precipitación según la dirección del viento en superficie a las 0 horas, Zaragoza (1990-2000). . . . .	88
3.30	Porcentaje mensual de días de precipitación observado y ajustado en Zaragoza, según distintos modelos. . . . .	94
3.31	Correlograma de la serie de ocurrencia observada y autocorrelaciones estimadas con <i>CM est</i> , izda., y <i>CM sondeos</i> , dcha., Zaragoza (1990-1997). . . . .	98
3.32	Percentiles de la distribución de la longitud de racha seca en Diciembre: datos observados y simulados a partir de <i>CM est.</i> . . . .	101
3.33	Percentiles de la distribución de la longitud de racha seca en Diciembre: datos observados y simulados a partir de <i>CM sondeos.</i> . . . .	102
3.34	Percentiles de la distribución de la longitud de racha húmeda en Mayo: datos observados y simulados a partir de <i>CM temp.</i> . . . .	102
3.35	Percentiles de la distribución de la longitud de racha húmeda en Mayo: datos observados y simulados a partir de <i>CM sondeos.</i> . . . .	103

3.36 Efecto del rango de temperatura del día  $t$  en el modelo  $CM\ temp$  en los cuatro observatorios. . . . . 108

3.37 Efecto del rango de temperatura del día  $t - 1$  en el modelo  $CM\ temp$  en los cuatro observatorios. . . . . 108

3.38 Efecto de la variable que representa la variación diaria de temperatura en los modelos con temperatura y presión de Agoncillo y Zaragoza. . . . . 109

3.39 Izda.: Efecto de la cantidad del día previo en el modelo de cantidad en Reinosa. Dcha.: Idem del rango de temperatura en el día  $t$ . . . 124

3.40 Histograma y diagrama de caja del percentil 10 de la distribuciones de cantidad ajustadas en Reinosa (1912-1959). . . . . 125

3.41 Histograma y qq-plot de los residuos del modelo de cantidad en Reinosa (1912-1959), según la ocurrencia de lluvia en el día previo. 126

3.42 Izda.: Cantidad media observada y ajustada, por meses, Reinosa (1912-1959). Dcha.: Suavizado de los valores diarios observados y ajustados. . . . . 126

3.43 Diagramas de dispersión de las cantidades medias ajustadas vs. observadas en Reinosa (1912-1959), por meses, por meses y según la ocurrencia en el día previo, por años, por meses y años. . . . . 127

3.44 Izda.: Cantidad media observada y ajustada, por meses, con el modelo de cantidad que no incluye  $Q_{t-1}$ , Tortosa (1942-1981). Dcha.: Suavizado de los valores diarios observados y ajustados. . . . . 129

3.45 Sup.: Funciones de densidad Exponencial y Gamma ( $\nu = 2.83$ ) con valor medio igual al observado. Inf.: Cociente entre ambas funciones. 130

3.46 Izda.: Cantidad media observada y ajustada, por meses, con el modelo de cantidad, Tortosa (1942-1981). Dcha.: Suavizado de los valores diarios observados y ajustados. . . . . 131

3.47 Diagramas de dispersión de las cantidades medias ajustadas vs. observadas en Tortosa (1942-1981). . . . . 131

3.48 Histograma y diagrama de caja del percentil 10 de las distribuciones ajustadas por el modelo de cantidad, Tortosa (1942-1981). . . 132

3.49 Izda.: Cantidad media observada y ajustada, por meses, con el modelo de cantidad, Tortosa (1982-1991). Dcha.: Suavizado de los valores diarios observados y ajustados. . . . . 133

3.50 Izda.: Cantidad media observada y ajustada, por meses, con el modelo de cantidad, Agoncillo (1978-1992). Dcha.: Suavizado de los valores diarios observados y ajustados. . . . . 135

3.51 Diagramas de dispersión de las cantidades medias ajustadas vs. observadas en Agoncillo (1982-1991). . . . . 135

3.52 Histograma y diagrama de caja del percentil 10 de las distribuciones ajustadas, Agoncillo (1978-1992). . . . . 136

3.53	Izda.: Cantidad media observada y ajustada, por meses, Agoncillo (1993-1997). Dcha.: Suavizado de los valores diarios observados y ajustados. . . . .	137
3.54	Izda.: Cantidad media observada y ajustada, por meses, con el modelo de superficie, Zaragoza (1990-1997). Dcha.: Suavizado de los valores diarios observados y ajustados. . . . .	139
3.55	Diagramas de dispersión de las cantidades medias ajustadas con el modelo con información de superficie vs. observadas en Zaragoza (1990-1997). . . . .	140
3.56	Gráficos basados en los residuos de la deviance y medidas de influencia del modelo que utiliza información de superficie en Zaragoza. 140	
3.57	Efectos asociados a la dirección y velocidad del viento en el modelo con medidas del radiosondeo, Zaragoza. . . . .	142
3.58	Izda.: Cantidad media observada y ajustada, por meses, con el modelo con información del radiosondeo, Zaragoza (1990-1997). Dcha.: Suavizado de los valores diarios observados y ajustados. . .	142
3.59	Diagramas de dispersión de las cantidades medias ajustadas con el modelo que usa información del radiosondeo vs. observadas en Zaragoza (1990-1997). . . . .	143
3.60	Diagramas de caja de las cantidades observadas en días con y sin radiosondeo, por meses, Zaragoza (1990-1997). . . . .	144
3.61	Histograma y diagrama de caja del percentil 10 de las distribuciones ajustadas por el modelo con información del radiosondeo, Zaragoza (1990-1997). . . . .	144
3.62	Gráficos basados en los residuos de la deviance y medidas de influencia del modelo que utiliza información del radiosondeo. . . . .	145
3.63	Izda.: Cantidad media observada y ajustada, por meses, con el modelo de cantidad que utiliza información de radiosondeos, Zaragoza (1998-2000). Dcha.: Suavizado de los valores diarios observados y ajustados. . . . .	146
3.64	Frecuencias de las cantidades de lluvia positivas, entre 1 y 100 décimas de litro, en Reinosa y Agoncillo. . . . .	149
3.65	Frecuencias de las cantidades de lluvia positivas, entre 1 y 100 décimas de litro, en Zaragoza y Tortosa. . . . .	150
3.66	Efecto de la cantidad en el día previo en los distintos modelos en que interviene. . . . .	152
3.67	Efecto del rango de temperatura en los distintos modelos de cantidad. 153	
3.68	Coefficiente de variación frente a cantidad media en 10 grupos de observaciones seleccionadas según el valor ajustado del modelo de cantidad. . . . .	154

3.69	Media anual de las cantidades positivas observadas y ajustadas en Tortosa, en los periodos de estimación y validación. . . . .	157
4.1	Áreas OPR, HIR y CAN del modelo numérico HIRLAM. . . . .	165
4.2	Efecto de la presión atmosférica en el modelo de previsión de ocurrencia. . . . .	169
4.3	Efecto de la dirección del viento en 500hPa a las 12h. . . . .	170
4.4	Comportamiento del modelo de previsión de ocurrencia (1990-1997). . . . .	171
4.5	Comportamiento del modelo de previsión de ocurrencia, periodo de validación (1998-2000). . . . .	172
4.6	Efecto de la dirección del viento en 500hPa a las 12h en el modelo para los meses templados. . . . .	177
4.7	Izda.: Cantidad media observada y ajustada, por meses, con el modelo de previsión de cantidad. Dcha.: Suavizado de los valores diarios observados y ajustados. . . . .	188
4.8	Izda.: Valores suavizados de las cantidades diarias observadas y previstas TP por HIRLAM. Dcha.: Desviación típica de esas cantidades, por meses. . . . .	191
4.9	Izda.: Valores suavizados de las cantidades diarias observadas y previstas LSP. Dcha.: Desviación típica por meses. . . . .	192
4.10	Izda.: Valores suavizados de las cantidades diarias observadas y previstas CP. Dcha.: Desviación típica por meses. . . . .	192
4.11	Izda.: Valores suavizados de las cantidades diarias observadas y previstas por HIRLAM en los días con precipitación. Dcha.: Desviación típica por meses. . . . .	194
4.12	Izda.: Valores suavizados de las cantidades diarias observadas y previstas por HIRLAM, cuando éstas son positivas. Dcha.: Desviación típica por meses. . . . .	195
4.13	Diagramas de barras de las frecuencias absolutas de las cantidades entre 1 y 20 décimas de litro observadas y previstas TP, LSP y CP. . . . .	196
4.14	Suavizado de la frecuencia relativa de lluvia diaria superior a los umbrales especificados, observada y prevista TP por HIRLAM. . . . .	197
4.15	Suavizado de la frecuencia relativa de lluvia diaria, observada y prevista LSP, superior a los umbrales especificados. . . . .	198
4.16	Suavizado de la frecuencia relativa de lluvia diaria, observada y prevista CP, superior a los umbrales especificados. . . . .	198
4.17	Suavizado de la frecuencia relativa de ocurrencia de lluvia observada y de lluvia TP igual o superior a los umbrales especificados. . . . .	201
5.1	Posición de las celdas consideradas del modelo CGCM1. . . . .	221

5.2	Datos diarios de precipitación y humedad en superficie observadas y generadas por CGCM1, periodo 1990-2000. . . . .	225
5.3	Humedad específica en los geopotenciales 850hPa y 500hPa observadas y generadas por CGCM1, periodo 1990-2000. . . . .	226
5.4	Temperatura máxima y mínima observadas y generadas por CGCM1, periodo 1990-2000. . . . .	228
5.5	Temperatura en los niveles geopotenciales 850 y 500hPa observadas y generadas por CGCM1, periodo 1990-2000. . . . .	229
5.6	Rango de temperatura en superficie y diferencia de temperatura entre los niveles geopotenciales 850 y 500hPa observada y generada por CGCM1, periodo 1990-2000. . . . .	230
5.7	Presión en superficie y altura del geopotencial 850hPa observadas y generadas por CGCM1, periodo 1990-2000. . . . .	233
5.8	Altura del geopotencial 500hPa y espesor de la capa 850-500hPa observados y generados por CGCM1, periodo 1990-2000. . . . .	234
5.9	Rosas de viento con la frecuencia de las direcciones observadas y simuladas, periodo 1990-2000. . . . .	236
5.10	Diagramas de caja por meses de la velocidad del viento en superficie y en 500hPa, observada y simulada, periodo 1990-2000. . . . .	237
5.11	Componentes de viento en superficie observadas y generadas por CGCM1, periodo 1990-2000. . . . .	238
5.12	Componentes de viento en 850hPa observadas y generadas por CGCM1, periodo 1990-2000. . . . .	239
5.13	Componentes de viento en 500hPa observadas y generadas por CGCM1, periodo 1990-2000. . . . .	240
5.14	Espectros estacionales de las anomalías de la altura del geopotencial 500hPa, observada y generada por CGCM1 para 1990-2000. . . . .	252
5.15	Espectros estacionales de las anomalías de la diferencia de temperatura entre los geopotenciales 850 y 500hPa, observada y generada por CGCM1 para 1990-2000. . . . .	252
5.16	Frecuencia relativa de días de precipitación observada y probabilidades ajustadas por el modelo <i>Down1</i> (1990-1997). . . . .	261
5.17	Correlogramas correspondientes a la serie de ocurrencia observada y a las series simuladas con el modelo de ocurrencia de <i>Down1</i> . . . . .	262
5.18	Izda.: Medias mensuales de las cantidades diarias observadas y ajustadas por el modelo de cantidad de <i>Down1</i> (1990-1997). Dcha.: Suavizado de los valores diarios. . . . .	263
5.19	Medias mensuales de las cantidades diarias observadas y ajustadas por el modelo de cantidad de <i>Down1</i> en el periodo de validación (1998-2000). . . . .	264

5.20	Frecuencias y probabilidades de ocurrencia ajustadas por <i>Down1</i> con los datos observados en el periodo 1990-2000 y con los datos simulados por CGCM1. . . . .	268
5.21	Valores medios de las cantidades positivas observadas y simuladas por el modelo <i>Down1</i> , usando las covariables generadas por CGCM1 para el periodo 1990-2000. . . . .	270
5.22	Frecuencia relativa de días de precipitación observada y probabilidades ajustadas por el modelo <i>Down2</i> con los datos observados en el periodo 1990-1997. . . . .	278
5.23	Izda.: Medias mensuales de las cantidades diarias observadas y ajustadas por el modelo de cantidad de <i>Down2</i> (1990-1997). Dcha.: Suavizado de los valores diarios. . . . .	279
5.24	Frecuencia media de lluvia observada y simulada con <i>Down2</i> utilizando los datos observados en el periodo 1990-2000. . . . .	281
5.25	Valores medios de las cantidades positivas observadas y simuladas por el modelo <i>Down2</i> utilizando los datos observados en el periodo 1990-2000. . . . .	282
5.26	Frecuencia media de lluvia observada y probabilidades de ocurrencia ajustadas por el modelo <i>Down2</i> utilizando los datos observados y los generados por CGCM1 para 1990-2000. . . . .	283
5.27	Valores medios de las cantidades observadas y simuladas por <i>Down2</i> utilizando los datos observados y los generados por CGCM1 para 1990-2000. . . . .	284
5.28	Diagramas de caja por meses y suavizado de los datos de temperatura mínima en superficie y de temperatura en la altura geopotencial 500hPa, generados por CGCM1 para los periodos 1990-2000 y 2090-2100. . . . .	287
5.29	Diagramas de caja por meses y suavizado de los datos de rango diario de temperatura, generados por CGCM1 en los periodos 1990-2000 y 2090-2100. . . . .	289
5.30	Diagramas de caja por meses y suavizado de los datos de presión atmosférica en superficie, generados por CGCM1 en los periodos 1990-2000 y 2090-2100. . . . .	289
5.31	Diagramas de caja por meses y suavizado de los datos de humedad específica en el geopotencial 500hPa, generados por CGCM1 en los periodos 1990-2000 y 2090-2100. . . . .	290
5.32	Diagramas de caja por meses y suavizado de los datos de altura del nivel geopotencial 850hPa y del nivel 500hPa, generados por CGCM1 en los periodos 1990-2000 y 2090-2100. . . . .	291

5.33	Diagramas de caja por meses y suavizado de los datos de espesor de la capa 850-500hPa, generados por CGCM1 en los periodos 1990-2000 y 2090-2100. . . . .	292
5.34	Probabilidades ajustadas por el modelo <i>Down2</i> con los datos observados y con los generados por CGCM1 para 2090-2100. . . . .	294
5.35	Valores medios de las cantidades positivas observadas y simuladas por el modelo <i>Down2</i> usando las covariables generadas por CGCM1 para 2090-2100. . . . .	295
5.36	Valores medios de las cantidades observadas y simuladas por <i>Down2</i> usando las covariables generadas por CGCM1 para 2090-2100. . . . .	297
5.37	Valores medios, por meses, de la cantidad diaria de lluvia observada, generada por CGCM1 para la celda que contiene a Zaragoza, obtenida del downscaling de <i>Down1</i> , <i>Down2</i> y un modelo sin información de humedad, usando la salida de CGCM1 para los periodos 1990-2000 y 2090-2100. . . . .	298

# Introducción

Esta memoria recoge buena parte de un trabajo dedicado a la modelización estocástica de la lluvia diaria, que ha tenido un dilatado proceso temporal. En ese periodo de tiempo la investigación ha ido evolucionando influida por la disponibilidad y el incremento de la información meteorológica, los requerimientos crecientes exigidos a los modelos, particularmente en la representación correcta de la persistencia de la precipitación, y el tipo de aplicaciones que se querían desarrollar.

En cualquier caso, aunque hemos trabajado con distintos modelos e incorporado paulatinamente nuevas colecciones de datos, nuestros objetivos generales se han mantenido. Estamos interesados en el diseño y puesta a punto de metodología útil para estimar modelos de lluvia diaria de diferente tipo y tenemos un interés especial en el desarrollo de herramientas para su validación y crítica.

La modelización elegida utiliza una representación del proceso de lluvia constituida por dos componentes, cada uno de los cuales requiere un sub-modelo propio: la ocurrencia de precipitación, representada por una variable binaria, y la cantidad medida en los días lluviosos, cuya distribución es positiva y asimétrica. En ambos casos la distribución de la variable de interés no es Gaussiana y el valor esperado depende de las covariables atmosféricas; por este motivo el marco de los modelos lineales generalizados (GLM) y sus extensiones, que permiten considerar la dependencia entre las sucesivas respuestas, es adecuado para realizar la inferencia estadística.

Ese marco ha resultado muy versátil y nos ha permitido ajustar diferentes modelos a lo largo de nuestra investigación. Las propiedades del proceso de ocurrencia las hemos analizado a través de cadenas de Markov, modelos de renovación alternante, modelos de regresión logística con efectos aleatorios y cadenas de Markov ocultas. Para la cantidad recogida en los días de lluvia hemos estimado modelos con distribuciones Weibull, Lognormal y Gamma.

El análisis de las cualidades de estos modelos, en el contexto de las aplicaciones de interés, nos ha decantado, por razones que se exponen en la memoria, por las cadenas de Markov para modelizar la ocurrencia y por los modelos con distribución de error Gamma para las cantidades.

Como se desprende de la lectura de la memoria, el trabajo está orientado a la resolución de problemas en Climatología. Hemos considerado siempre que los métodos estadísticos no son un fin en sí mismos sino una herramienta para resolver cuestiones; esto ha sido un acicate en nuestro trabajo y nos ha obligado a mantenernos próximos a los datos reales.

Otra apuesta de trabajo es la decisión de aplicar y ensayar la metodología en observatorios de la cuenca del Ebro, área donde hemos aplicado nuestra investigación y realizado distintos proyectos, tanto CICYT como de colaboración con la Oficina de Planificación Hidrológica de la Confederación Hidrográfica del Ebro. Una de las ventajas de esta decisión ha sido el contacto con profesionales del Instituto Nacional de Meteorología (INM), que han enriquecido nuestro trabajo. Por otra parte, el ámbito espacial reducido no impide disponer de una diversidad de climas en la que ensayar los métodos; la cuenca del Ebro, que se extiende entre el Cantábrico y el Mediterráneo, está llena de contrastes, dispone de una franja pirenaica y tiene en el centro una de las zonas más áridas de la Península.

Mostraremos, en el capítulo 3, las capacidades de la modelización propuesta en observatorios de características climáticas muy diferentes y con información atmosférica dispar. Además, los modelos se aplicarán a la resolución de dos problemas distintos:

1. La predicción de la precipitación en un observatorio, a lo que se dedica el capítulo 4.
2. El downscaling de la precipitación diaria a escala local, a partir de la información generada por un modelo de circulación general (GCM), que se desarrolla en el capítulo 5.

Los problemas y modelos se tratan en un contexto real lo que implica las dificultades, y ventajas, propias del trabajo con bases de datos de gran tamaño:

- los análisis estadísticos han requerido un esfuerzo computacional importante, que se ha resuelto con el uso de S-plus,

- se ha debido llevar a cabo una cuidadosa y prolija preparación de las bases de datos,
- hemos realizado siempre el proceso de ajuste de los modelos reservando una fracción del conjunto de observaciones para su validación.

## Estructura de la memoria

La memoria consta de 5 capítulos y se presenta en dos volúmenes. El primer volumen incluye el texto principal, en el que se describen las propiedades y conclusiones de los modelos, cuya lectura se ha tratado de facilitar utilizando numerosas figuras y tablas resumen que pretenden hacer el análisis menos tedioso. El segundo contiene tablas en las que se detalla la información y resultados descritos en el texto del volumen 1. Esas tablas se organizan en tres anexos, A, B, C, que corresponden, respectivamente, a los capítulos 3 a 5 de la memoria.

Los capítulos comienzan por una sección introductoria en la que se fijan sus objetivos y se describe el contenido de las distintas secciones. Los capítulos 3 a 5 contienen secciones finales dedicadas a resumir las conclusiones relativas tanto a la metodología propuesta como a su aplicación concreta; se señalan también los aspectos que no están resueltos o son mejorables y las correspondientes acciones con las que proseguirá nuestra investigación.

A continuación vamos a describir el contenido de cada capítulo, presentando los problemas que se intentan resolver y avanzando algún resultado y conclusión.

### Capítulo 1

Éste es un capítulo introductorio sobre los tipos de modelos estadísticos de lluvia que se encuentran en la literatura y sobre el marco en el que se va a realizar el proceso de inferencia estadística.

En la sección 1.2 se realiza una revisión bibliográfica de los modelos de lluvia diaria, tanto de los puramente estocásticos como de los que incluyen información de covariables climáticas.

En la sección 1.3 se revisan los conceptos básicos sobre los modelos lineales generalizados (GLM) así como de sus extensiones, entre ellas los modelos condicionales, que permiten tener en cuenta la existencia de dependencia entre las observaciones.

## Capítulo 2

El capítulo 2 está dedicado a proponer un esquema de validación y crítica con el que se van a valorar los modelos ajustados en la memoria. Éstos son extensiones condicionales de los GLM y, por lo tanto, puede usarse con ellos el esquema de chequeo habitual. En el caso de los modelos con respuesta binaria, sin embargo, una herramienta como el análisis de residuos no es útil. Por este motivo, la sección 2.2 se dedica a la revisión de criterios específicos para la evaluación de los modelos de precipitación, particularmente de los de ocurrencia.

En la sección 2.3 se propone una metodología que pretende valorar el comportamiento de los modelos en aspectos como su capacidad para clasificar correctamente las observaciones, reproducir el ciclo estacional o la evolución de la precipitación a lo largo de los años. Históricamente, los modelos de lluvia diaria han sido insuficientes para reproducir adecuadamente la distribución de las longitudes de las rachas de días secos y húmedos, por ello valoraremos el grado de éxito de los modelos ajustados en este aspecto, lo que requerirá emplear simulación.

## Capítulo 3

En este extenso capítulo se presenta la metodología utilizada para la construcción de los modelos de lluvia diaria y su aplicación a cuatro observatorios situados a lo largo del curso del Ebro, que representan climas muy distintos: Reinosa (Cantabria), Agoncillo (La Rioja), aeropuerto de Zaragoza, Tortosa (Tarragona). El capítulo tiene dos partes, una dedicada a los modelos de ocurrencia y otra a los de cantidad.

Los modelos de ocurrencia ajustados son cadenas de Markov cuyas probabilidades de transición pueden estimarse mediante regresión logística. En la sección 3.3 se propone una estrategia de construcción en la que se estudia, en pasos sucesivos, la significación de las covariables (indicadores de la ocurrencia en días previos, términos armónicos para representar el ciclo anual y covariables climáticas). Se obtienen así modelos que usan distinto grado de información: homogéneos, no homogéneos con probabilidades que recogen la estacionalidad del fenómeno, con probabilidades dependientes de las covariables registradas en un observatorio termopluiométrico y, por último, modelos que requieren información que sólo se registra en algunos observatorios de primer orden.

En las secciones 3.4 a 3.7 se presentan los ajustes realizados en cada uno

de los observatorios. La sección 3.8 se dedica a comparar los resultados y a destilar las conclusiones comunes sobre la modelización de la ocurrencia.

Las siguientes secciones se dedican a la modelización de la cantidad registrada en los días húmedos, usando un GLM con error Gamma. En la sección 3.9 se presenta la metodología para realizar la estimación y se propone una batería de medidas de evaluación. Éstas incluyen algunas utilizadas en los modelos de ocurrencia, como los coeficientes e índices que miden la proximidad entre los valores medios por meses, y otras específicas que valoran cómo se sitúan las observaciones entre las clases definidas por los percentiles de su distribución ajustada.

Los modelos estimados, sección 3.10, muestran problemas en el ajuste de las observaciones próximas al valor 0, achacables a la ausencia de información relevante y no a una selección incorrecta de la distribución de error. Los modelos de cantidad obtenidos producen un ajuste menos satisfactorio que los de ocurrencia, sin embargo superan los niveles logrados por otros autores en observatorios de características similares.

## Capítulo 4

El objetivo de este capítulo es construir un modelo que prediga la precipitación en 24 horas en un observatorio, utilizando la información disponible hasta las 18 horas del día anterior, y comparar sus resultados con el operativo que dispone el INM para establecer esa previsión en análogas condiciones. En la sección 4.2 se revisan los elementos de ese procedimiento operativo de predicción.

En la sección 4.3 se implementa un modelo de previsión para el aeropuerto de Zaragoza. Discutimos la necesidad de establecer modelos diferenciados para las distintas épocas del año y concluimos que éstos sólo suponen ventaja en cuanto a la simplificación de la estructura de los predictores lineales pero no encontramos mejoras importantes en el grado de éxito en la predicción. El modelo de cantidad no resulta útil para predecir, puesto que produce ajustes insuficientes con la información disponible en el día previo.

En la sección 4.4 demostramos que el modelo estadístico de previsión desarrollado tiene un grado de éxito mayor que el obtenido directamente de las previsiones proporcionadas por el modelo numérico HIRLAM, en el que se basan las predicciones del INM.

## Capítulo 5

El capítulo 5 se dedica a desarrollar y realizar un ‘downscaling’ de la precipitación, a escala diaria y local, en un escenario de cambio climático; es decir, a obtener proyecciones a largo plazo de la lluvia a partir de otras variables meteorológicas, proporcionadas por un experimento realizado con un modelo de circulación general.

Tras unas secciones en las que se introducen los elementos que intervienen en la investigación del cambio climático y el papel de los métodos estadísticos en el downscaling se propone, en la sección 5.5, una metodología para realizar ese proceso basada en un modelo estadístico similar a los presentados en el capítulo 3.

En la sección 5.6 se lleva a cabo la selección de las variables para las que el GCM, en nuestro caso CGCM1 desarrollado por el Canadian Center for Climate Modelling and Analysis, genera valores cuya distribución corresponde con la observada. El control de las variables se basa en el análisis, con métodos descriptivos, de la distribución marginal y en la aplicación de tests de hipótesis; se analiza también el espectro de las series de cada variable y la estructura de correlación entre ellas. La conclusión es que las variables generadas para el punto de la red de CGCM1 más próximo a Zaragoza no reproducen el clima observado, aunque sí lo hacen las anomalías de la mayoría de ellas.

El siguiente paso es la construcción de un modelo de lluvia que utilice las variables bien representadas por el GCM, sección 5.7. El diagnóstico de ese modelo requiere el paso adicional, que se lleva a cabo en la sección 5.8, de valorar si, cuando se usa con los valores de las covariables generadas por el GCM en la situación climática actual, produce un régimen de precipitación análogo al observado; si no es así, debe analizarse las causas de las desviaciones detectadas y reformular el modelo para evitar sus sesgos, lo que hacemos en la sección 5.9. Una vez realizado este proceso de ajuste, redefinido el modelo y comprobado que funciona satisfactoriamente, en la sección 5.10 se realiza la proyección de la lluvia para el periodo 2090-2100, en el escenario IS92a.

El método de downscaling que proponemos tiene propiedades que lo hacen superior a otros en distintos aspectos. Genera series de lluvia diaria, lo que permite valorar no sólo los cambios en el comportamiento agregado sino también en la distribución de las rachas o en la cantidad en un día húmedo. El modelo incluye información de variables de distinto tipo, lo que evita que

el downscaling esté dominado por la presión, como ocurre en los métodos basados en la situación climática reinante, o por la temperatura. Finalmente, la metodología propuesta está abierta a la ampliación de la base de información usada, lo que permitiría el uso de otras fuentes de datos, como el reanálisis NCEP/NCAR, o la incorporación de nuevas variables.



# Capítulo 1

## Modelos de lluvia. Modelos lineales generalizados

### 1.1 Introducción

La necesidad del agua como un recurso necesario para el desarrollo de prácticamente cualquier actividad humana, ha implicado una preocupación desde antiguo por el estudio de los procesos naturales que involucran a dicho elemento: flujos de ríos, evaporación natural y, desde luego, la precipitación. Esta preocupación se refleja en la existencia de una amplia comunidad científica dedicada al estudio de temas relacionados con el agua, que incluye a numerosas ramas de la Ciencia y que ha generado una literatura muy abundante.

En particular se pueden encontrar un gran número de artículos y monografías dedicados al análisis del fenómeno de la precipitación, considerado como la realización de un proceso estocástico, y tratado en escalas temporales y espaciales muy diferentes. De la dimensión y tipo de problema depende el modelo propuesto.

Cabe destacar el interés especial que los investigadores dedican recientemente al efecto que puede tener un posible cambio climático sobre el ciclo natural del agua. Los distintos informes del Panel Intergubernamental para el Cambio Climático, IPCC, se refieren a este tipo de estudios y a su utilidad para establecer las previsiones de cambio. Estas previsiones se basan en las salidas que producen los modelos de circulación general (GCM) que, sin duda, son las mejores herramientas actualmente disponibles para la investigación sobre la evolución del clima global en los distintos escenarios planteados a largo plazo. Sin embargo, hay un amplio acuerdo en que esos modelos, debi-

do a su insuficiente resolución espacial, producen resultados contradictorios y, en consecuencia, poco creíbles en lo que respecta a la precipitación local y regional, Houghton y otros (1996) [63], Houghton y otros (2001) [64]. Uno de los procedimientos utilizados para solucionar este problema consiste en desarrollar modelos estadísticos que permitan realizar el ‘downscaling’ de los resultados obtenidos para variables atmosféricas de gran escala a las variables climáticas que tienen un comportamiento dependiente de factores más locales, como es la precipitación.

Periódicamente se publican revisiones sobre modelos de precipitación susceptibles de ser utilizados en el ‘downscaling’ de los resultados propuestos por los GCM: Lettenmaier (1995) [81], Goodess (2000) [50] o Houghton y otros (2001) [64] en el último informe del IPCC. A este respecto es interesante referirse al trabajo de Wilby y otros (1998) [117], en el que se comparan distintos modelos estadísticos para el downscaling de la precipitación diaria (basados en redes neuronales y técnicas de regresión) junto con dos modelos estocásticos que modelan la serie de ocurrencia de lluvia mediante una cadena de Markov, el primero, y un modelo de renovación alternante con distribución Binomial Negativa, el segundo y ambos con distribución Gamma para representar la cantidad de lluvia en un día con precipitación. El análisis de una serie de medidas diagnósticas relativas tanto a la ocurrencia como a la cantidad acumulada en distintos meses, lleva a los autores a concluir que los métodos basados en los modelos estocásticos son superiores en la mayoría de los diagnósticos.

Esta memoria se dedica al desarrollo y explotación de un modelo estadístico para la precipitación diaria. La distribución de esta variable respuesta es mixta, con probabilidad no nula en el valor 0 y distribución asimétrica cuando la cantidad de lluvia es positiva. Por la posibilidad que tienen de tratar tanto respuestas discretas como continuas no gaussianas, los modelos lineales generalizados (GLM) constituyen un marco adecuado para la estimación de relaciones entre los parámetros de las distribuciones que representan la precipitación diaria y la información proporcionada por distintas covariables. La existencia de dependencia entre la precipitación observada en días consecutivos hace necesario el uso de extensiones de los GLM que consideren la relación entre las observaciones del proceso.

El contenido de este capítulo se centra en una revisión de los procesos estocásticos que se han utilizado en la modelización de la precipitación diaria a escala local, aunque se señalan también algunas referencias que han tratado el fenómeno en otras escalas temporales o espaciales. Además, se revisan

brevemente los conceptos básicos sobre modelos lineales generalizados, así como sus extensiones que permiten considerar la existencia de dependencia entre las observaciones.

## 1.2 Revisión de modelos estocásticos de precipitación diaria

La escala temporal en la que se estudia el fenómeno de la lluvia hace que la respuesta, la cantidad registrada durante la unidad de tiempo considerada, presente un comportamiento estadístico muy diferente. Si se trata de la cantidad total anual de precipitación, la distribución puede ser aproximadamente normal en muchas latitudes; sin embargo, esta hipótesis no será adecuada cuando el periodo considerado sea menor: mes, día u hora. Si se analiza una serie de datos pluviométricos de escala inferior a la anual son apreciables las siguientes características:

1. Estacionalidad del fenómeno. La lluvia es más frecuente o abundante en algunas épocas del año, siguiendo un ciclo anual.
2. Presencia de observaciones con valor cero. Dada la intermitencia del fenómeno pueden encontrarse épocas prolongadas en las que no se registra precipitación.
3. Distribución fuertemente asimétrica de las observaciones que superan el umbral apreciable. Cuanto menor es la escala temporal de registro, mayor es la frecuencia de valores cercanos a cero, a la vez que es posible observar fuertes precipitaciones que proporcionan una cantidad mucho mayor que la moda.

Estas circunstancias, en particular las dos últimas, impiden considerar una estrategia de modelización habitual de series temporales como la basada en la familia ARMA.

En los trabajos sobre la precipitación diaria en un punto se opta habitualmente por modelar separadamente el llamado proceso de ocurrencia de lluvia, si llueve o no, y el correspondiente a la cantidad recogida cuando llueve, Stern y Coe (1984) [108], Woolhiser (1992) [123], Smith (1994) [107], Wilks (1998) [120], aunque hay autores que modelan el fenómeno de forma integral, Chang y otros (1984) [34], Bardossy y Plate (1992) [19], Colomer (1995) [27], Jothiyangkoon y otros (2000) [73].

El carácter estacional de la precipitación suele abordarse bien fragmentando el ciclo anual en intervalos en donde el fenómeno puede considerarse homogéneo, meses o estaciones, o proponiendo modelos temporalmente no homogéneos.

### 1.2.1 Modelos de ocurrencia de lluvia diaria

El modelo de la cadena de Markov (CM) constituye un claro candidato para representar la sucesión de días húmedos y secos. Los estados de la cadena se definen ‘seco’ y ‘húmedo’, según que la cantidad de lluvia registrada sea inferior o superior a un umbral establecido. Pueden definirse cadenas con más estados, considerando una partición del rango de valores de la cantidad medida, Colomer (1995) [27], pero, como se ha señalado, lo habitual es tratar separadamente el aspecto de la ocurrencia de lluvia y el de la cantidad registrada.

Los modelos markovianos de ocurrencia más simples utilizan matrices de probabilidades de transición homogéneas para periodos que pueden comprender uno o varios meses: Buishand (1977) [23], Smith (1994) [107] o Wilby y otros (1998) [117]. En España, Martín-Vide y Gómez (1999) [87] analizan la capacidad de las cadenas de Markov homogéneas para reproducir la frecuencia de las longitudes de rachas secas en 35 observatorios peninsulares, en especial se interesan por el ajuste de las rachas de gran longitud.

Desde el punto de vista estadístico, una referencia esencial en este campo es el trabajo de Stern y Coe (1984) [108]. Estos autores formularon un modelo de cadena de Markov no homogénea para la ocurrencia de lluvia y lo estimaron mediante regresión logística (un GLM). El modelo permite ajustar las probabilidades de transición en cada día del año y resulta parsimonioso ya que la estacionalidad se introduce a través de armónicos de Fourier; por otra parte, esta aproximación permite un análisis sencillo del orden de memoria de la cadena. Este modelo, que se ha utilizado ampliamente, fue aplicado por Abaurrea y otros (1994) [1] para la representación de la precipitación en observatorios de la región aragonesa.

El uso de covariables climáticas en los modelos de precipitación viene impuesto, por una parte, por la dificultad de explicar la gran variabilidad de la respuesta y, más recientemente, por el interés en relacionar la lluvia con otras variables con el fin de realizar el downscaling estadístico.

El marco de la regresión logística permite, de manera natural, considerar la dependencia de la probabilidad de ocurrencia de lluvia respecto de otras covariables climáticas. Así Woolhiser y otros (1993) [121] analizan la influencia del índice SOI (Southern Oscillation Index) en la lluvia diaria del sudoeste de Norteamérica; Klein Tank y Buishand (1995) [77] ajustan un modelo no homogéneo en el que introducen información sobre la humedad, la presión y la radiación solar. Abaurrea y Asín (1997) [3] y (1997) [4] mo-

delan la precipitación en los observatorios de Tortosa y Reinosa utilizando como covariables las temperaturas máxima y mínima diarias.

Otra línea de trabajo, dentro de una dirección que trata de ampliar la información contenida en los modelos, se basa en hacer que sus parámetros dependan del estado climático reinante. En esta línea se encuentran los trabajos de Bardossy y colaboradores que representan la ocurrencia de lluvia en distintos observatorios alemanes, relacionando su probabilidad con el estado de circulación atmosférica, Bardossy y Caspary (1990) [17]. En Bardossy y Plate (1991) [18] se establece un modelo semi-markoviano para la secuencia diaria de los estados atmosféricos, cuya duración se representa por una distribución Poisson generalizada, y se propone que la probabilidad de ocurrencia depende del estado. Hay y otros (1991) [56] proponen un modelo semejante utilizando la distribución Geométrica para representar el tiempo de permanencia en el estado atmosférico. Wilby (1994) [115] presenta un modelo de cadena de Markov para la evolución diaria de los tipos de situación atmosférica y propone que la probabilidad de ocurrencia en un día dependa del estado atmosférico reinante y de la ocurrencia en el día previo; posteriormente, Wilby (1995) [116] plantea que la probabilidad de lluvia en un día dependa también del número de frentes de actividad atmosférica que se producen en dicho día.

Un esquema alternativo de modelización del proceso de ocurrencia se basa en el uso de modelos de renovación alternante para la secuencia de rachas de días secos y húmedos. Buishand (1977) [23], Abaurrea y otros (1994) [1] y Wilby y otros (1998) [117] utilizan la distribución Binomial Negativa para modelar la longitud de las rachas, Semenov y Barrow (1997) [103] usan una mezcla de Exponenciales, Kottegoda y otros (2000) [78] representan la longitud de las rachas húmedas mediante una distribución Geométrica y emplean una distribución Logarítmica para las longitudes de las rachas de días sin lluvia.

Todos los modelos revisados hasta aquí pertenecen a la categoría de los modelos ‘observation driven’, de acuerdo con la clasificación de Cox. En la modelización de la ocurrencia de lluvia se han utilizado también modelos del tipo denominado ‘parameter driven’.

Entre los modelos que suponen un proceso subyacente, no observado, que permite aleatorizar la probabilidad de ocurrencia, cabe citar el modelo Markov-renovación de Foufoula-Georgiou y Lettenmaier (1987) [42] consistente en un proceso de renovación con tiempos de recurrencia geométricos,

con parámetros dependientes del estado de una cadena de Markov subyacente. El modelo Markov-Bernoulli de Smith (1987) [106] propone la existencia de una cadena de Markov oculta de dos estados, uno de los cuales representa una situación en la que la precipitación es imposible, mientras que en el otro existe una probabilidad positiva de ocurrencia cuyo valor depende de la época del año.

El modelo hidden-Markov de Zucchini y Guttorp (1991) [126] es uno de los más aplicados en este campo. Se basa en una cadena de Markov oculta tal que, dado su estado, el proceso observado de ocurrencia es de variables independientes y donde la probabilidad de lluvia está ligada a dicho estado. Los modelos de cadena de Markov oculta han sido utilizados para establecer modelos de precipitación en la hipótesis de que existen covariables influyentes no disponibles; Abaurrea y Asín (1999) [6] lo aplicaron a observatorios de la Península Ibérica donde no se dispone de la secuencia histórica de estados atmosféricos.

La estacionalidad se ha abordado en los modelos hidden-Markov de forma semejante a la indicada para las cadenas de Markov. Zucchini y Guttorp (1991) [126] consideran que la cadena oculta es homogénea durante breves periodos, bimestres o trimestres, y que tiene un número reducido de estados, mientras que MacDonald y Zucchini (1997) [86] modelan los datos de Durban con una única cadena, de dos estados y no homogénea, cuyas probabilidades de transición dependen de los armónicos de una serie de Fourier. Este tipo de modelos se han construido también utilizando covariables como la presión, la temperatura, las alturas geopotenciales o la humedad relativa, Hughes y Guttorp (1994) [66], Bellone y otros (1999) [21], Hughes y otros (1999) [67]. En el trabajo de Abaurrea y Asín (1999) [6] se planteaba la construcción de modelos hidden-Markov para la ocurrencia diaria de precipitación en el observatorio de Agoncillo (La Rioja); la temperatura y la presión en superficie se empleaban como información útil, tanto en los predictores de las probabilidades de transición de la cadena oculta como en la probabilidad de ocurrencia de lluvia condicionada al estado de la cadena.

### 1.2.2 Modelos de cantidad de lluvia

En la modelización de la cantidad de precipitación medida en un día lluvioso se han utilizado distintas distribuciones de carácter asimétrico: Exponencial, Smith (1994) [107]; Gamma, Stern y Coe (1984) [108], Smith (1994) [107], Abaurrea y otros (1994) [1], Buishand y Klein Tank (1996) [24], Kottegoda y otros (2000) [78]; Lognormal, Colomer (1995) [27] y la distribución de Wei-

bull, Abaurrea y otros (1995) [2], Jolliffe y Hope (1996) [71], Sharma (1996) [105]. Resulta menos habitual usar transformaciones como procedimiento para conseguir que la variable respuesta tenga una distribución Normal o siga alguna de las citadas anteriormente: Smith (1994) [107] utiliza las distribuciones habituales y considera también una transformada Gamma y una transformada Pareto.

En algunos trabajos, cuando la relación observada entre media y varianza no se corresponde con la de una distribución Gamma, el modelo más habitual, se opta por la mezcla de Exponenciales, Woolhiser y Roldán (1986) [122], Woolhiser y otros (1993) [121], Semenov y Barrow (1997) [103], Wilks (1998) [120], o por el producto de una v.a. Exponencial y una variable Uniforme, Hay y otros (1991) [56], Wilby (1994) [115].

Algunos autores introducen en los modelos de cantidad la influencia de covariables climáticas: Wilby (1995) [116] modela la cantidad de lluvia positiva mediante una distribución Exponencial con parámetro dependiente del tipo de clima reinante y del número de frentes que se dan en el día; Goodess (2000) [50] con una distribución Gamma cuyos parámetros dependen de la situación atmosférica.

Una hipótesis frecuente es considerar el proceso de cantidades formado por variables independientes e independiente del proceso de ocurrencia. Existen autores, sin embargo, que encuentran relación entre ambos procesos y que consideran que los parámetros dependen de la ocurrencia observada en los días previos, Buishand (1977) [23], Stern y Coe (1984) [108], o de las cantidades registradas en días anteriores, Smith (1994) [107], Abaurrea y otros (1995) [2], Grunwald y Jones (2000) [52]. Kottegoda y otros (2000) [78] encuentran que en los primeros días de una racha húmeda las cantidades medias registradas son mayores, por lo que proponen que los parámetros de la distribución Gamma dependan de la posición del día dentro de la racha húmeda.

Hay autores que deducen los resultados relativos a la lluvia diaria a partir de modelos para una escala de tiempo inferior. Así, Katz y Parlange (1995) [74] obtienen las propiedades diarias del proceso mediante la agregación de los resultados en un modelo horario, consistente en una cadena de Markov de primer orden, como modelo de ocurrencia, y un modelo AR(1) gaussiano aplicado a una transformación de la cantidad. De forma semejante, Gyasi-Agyei y Willgoose (1999) [54] obtienen sus resultados mediante agregación en un modelo para la lluvia medida en periodos de 15 minutos, en el que

la sucesión de cantidades registradas se modela como el producto de una cadena de Markov de dos estados por un proceso obtenido al aplicar una transformación exponencial a un proceso AR gaussiano.

### 1.2.3 Modelización de la lluvia observada

Aunque, como se ha señalado, no es la aproximación habitual, existen autores que consideran como respuesta la cantidad registrada de lluvia, sea ésta cero o positiva.

Chang y otros (1984) [34] establecen una partición de la cantidad observada en 3 estados, siendo uno de ellos el estado seco, y proponen un modelo DARMA (ARMA discreto) para representar su proceso. En el modelo DARMA( $p, q$ ) un sorteo aleatorio i.i.d. señala para cada día si la respuesta coincide con una componente de una sucesión de v.a. i.i.d. de distribución discreta, con un retardo elegido al azar entre 0 y  $q - 1$ , lo que interpretan como su estructura MA, o bien corresponde a una componente de una secuencia de variables dependientes, con la misma distribución discreta, cuyo retardo se elige también al azar entre 1 y  $p$ .

Colomer (1995) [27] propone un modelo de cadena de Markov cuyos estados corresponden a una partición del rango de valores de la cantidad de lluvia. Define 5 estados y considera que la cantidad de lluvia diaria asociada a un estado con precipitación sigue una distribución Lognormal truncada. Jothiyangkoon y otros (2000) [73] proponen un modelo semejante basado en 4 estados y una distribución Gamma truncada.

Bardossy y Plate (1992) [19] plantean que la cantidad de lluvia sigue una distribución mixta, con parámetros dependientes del estado atmosférico reinante. Modelan la cantidad mediante una transformación de una variable Normal. La dependencia temporal se modela considerando que, mientras el estado atmosférico permanece, la variable sigue un proceso AR(1) y, si se produce un cambio en el estado atmosférico, la variable se renueva.

### 1.2.4 Modelos en tiempo continuo

Un tipo de modelos de precipitación, no considerados en esta memoria, se basa en los procesos puntuales en tiempo continuo. A partir de estos modelos algunos autores obtienen propiedades de la precipitación agregada en distintas unidades de tiempo, en particular en la escala diaria. Como referencias destacables cabe señalar a Waymire y Gupta (1981) [114] y a Cox e Isham

(1994) [33] que basan sus modelos en procesos Poisson-cluster como los de Neyman-Scott y Bartlett-Lewis.

En el proceso de Neyman-Scott, los distintos episodios de un cluster comienzan en instantes que están separados del momento de llegada del cluster por un intervalo Exponencial. En los trabajos de Rodríguez-Iturbe y otros (1987) [98], (1988) [99] la duración e intensidad de cada episodio se representan mediante pulsos rectangulares. Sobre este esquema se han propuesto distintas generalizaciones, Entekhabi y otros (1989) [39], Cowpertwait (1994) [30], Cowpertwait y otros (1996) [31].

En el proceso de Bartlett-Lewis, para cada cluster y durante un tiempo aleatorio exponencial se producen llegadas de episodios de lluvia según otro proceso de Poisson. Este esquema se ha utilizado para representar la ocurrencia de lluvia en Onof y Wheeler (1993) [94], Gyasi-Agyei y Willgoose (1999) [54] y Gyasi-Agyei (1999) [53].

### 1.2.5 Modelos espacio-temporales

Aunque los análisis desarrollados en esta memoria son de carácter puntual y la variabilidad espacial no ha sido objeto de estudio, debe señalarse que algunos de los modelos citados han sido utilizados para representar la lluvia en una región mediante la integración en un modelo espacial de los modelos locales obtenidos para una red de puntos. Por ejemplo, Cowpertwait y otros (1996) [32] ajustan modelos de tipo Neyman-Scott a 112 observatorios del Reino Unido y posteriormente establecen un modelo global usando técnicas de interpolación sobre los parámetros ajustados en cada observatorio.

Alternativamente se han formulado modelos que son aplicables a múltiples puntos de observación. Smith (1994) [107] propone un modelo para la lluvia en dos observatorios que extiende el modelo local de Stern y Coe.

Otra vía utilizada consiste en definir un modelo para el estado climático reinante en una región que gobierne los parámetros del modelo de ocurrencia de lluvia en cada punto, tal como proponen Hay y otros (1991) [56] para la cuenca del río Delaware o Bardossy y Plate (1991) [18] para la cuenca del Ruhr. Finalmente los modelos hidden-Markov se han utilizado para la representación de la ocurrencia de lluvia en varios observatorios, bajo la hipótesis de que el estado de la cadena oculta representa la situación climática que afecta a toda la región, Hughes y Guttorp (1994) [65], Hughes y otros (1999) [67].

### 1.3 El marco de los modelos lineales generalizados

Los modelos lineales generalizados constituyen una herramienta versátil para abordar los problemas que surgen en este campo debido, por una parte, a la diversidad de distribuciones que incluyen, tanto para la modelización de respuestas discretas como continuas; por otra, porque los GLM, una extensión del modelo lineal, permiten analizar la relación entre la respuesta y otras variables que pueden explicar la variabilidad de la precipitación.

Los GLM, introducidos por Nelder y Wedderburn en 1972, son una generalización del modelo lineal clásico en la que las observaciones, independientes, de la variable respuesta siguen una distribución perteneciente a la familia exponencial. La media de la variable respuesta está funcionalmente relacionada con una combinación lineal de las variables explicativas, el predictor lineal, mediante una función monótona denominada función de enlace. El marco de los GLM incluye modelos estadísticos como el modelo lineal para respuestas con distribución Normal, la regresión logística y probit para respuestas Binomiales, los modelos loglineales para variables Multinomiales, los modelos con respuesta Poisson, Gamma o Inversa Gaussiana.

Entre las monografías dedicadas a estos modelos destaca la de McCullagh y Nelder (1989) [89] que constituye un libro de referencia tanto desde el punto de vista teórico como para la revisión de distintas aplicaciones y extensiones. Otras publicaciones con un enfoque más introductorio o aplicado son: Dobson (2002) [38] o Lindsey (1997) [84]. Fahrmeir y Tutz (1994) [40] revisan en su monografía posibles extensiones de los GLM que evitan la imposición de independencia entre las respuestas.

La estructura del modelo queda establecida por tres componentes:

1. Error o distribución de la respuesta, que debe pertenecer a la familia exponencial.

El vector de respuestas  $y_i, i = 1, \dots, n$ , está constituido por v.a. independientes con esperanza  $\mu_i$ , cuya función de densidad se puede expresar como:

$$f(y_i; \theta_i) = \exp \left( \frac{y_i \theta_i - b(\theta_i)}{a_i(\phi)} + c(y_i, \phi) \right)$$

donde se tienen las siguientes relaciones entre los momentos de la respuesta, los parámetros de posición  $\theta_i$ , de escala  $\phi$ , la función de pesos

$a_i(\phi)$  y la función  $b$ :

$$\mu_i = \frac{\partial b(\theta_i)}{\partial \theta_i}$$

$$Var(y_i) = \frac{\partial^2 b(\theta_i)}{\partial \theta_i^2} a_i(\phi) = \frac{\partial \mu_i}{\partial \theta_i} a_i(\phi)$$

En esta última expresión se llama función varianza al término  $v(\mu_i) = \partial \mu_i / \partial \theta_i$  que relaciona esa medida de variabilidad con la esperanza de la variable. Es habitual establecer que la función de pesos sea de la forma:

$$a_i(\phi) = \frac{\phi}{\varpi_i}$$

donde a  $\varpi_i$  se les denomina pesos a priori.

La familia exponencial incluye distribuciones continuas como la Gaussiana, Gamma, Inversa Gaussiana o discretas como la de Poisson y Binomial.

## 2. Predictor lineal.

El conjunto de variables explicativas, supuesto de dimensión  $p$ , se puede expresar en una matriz  $n \times p$  denotada  $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_n]^T$  que, junto con un vector formado por  $p$  parámetros desconocidos,  $\beta$ , proporcionan el predictor lineal,  $\eta = \mathbf{X}\beta$ , que representa la información de las covariables utilizada para explicar el comportamiento esperado de la respuesta.

## 3. Función de enlace.

La relación entre el valor del predictor lineal y la esperanza de la variable respuesta se establece a través de una función monótona y diferenciable  $g$ , denominada función de enlace:

$$\eta_i = g_i(\mu_i) = \mathbf{x}_i^T \beta$$

Habitualmente se considera la misma función de enlace para todos los casos.

Para cada error existe una función de enlace canónica que identifica el predictor lineal con el parámetro de posición  $\theta$ , lo que permite disponer de estadísticos suficientes para el vector  $\beta$ .

La estimación máximo-verosímil de este modelo se obtiene resolviendo el sistema de ecuaciones ‘score’, de expresión:

$$q_j(\mathbf{y}; \beta) = \sum_{i=1}^n \frac{y_i - \mu_i}{v(\mu_i)} \frac{\partial b(\theta_i)}{\partial \beta_j} = 0, \quad j = 1, \dots, p$$

Las estimaciones de los parámetros son consistentes y asintóticamente normales, con distribución  $N(\beta, \phi(\mathbf{X}^T \mathbf{W} \mathbf{X})^{-1})$ , donde  $\mathbf{W}$  es una matriz diagonal con elementos de la forma  $v(\mu_i)(g'(\mu_i))^2$ . La resolución de las ecuaciones de estimación requiere un método numérico denominado Fisher-scoring, que es una modificación del método de Newton-Raphson. Los programas estadísticos S-plus, SAS o GLIM tienen implementado el ajuste de estos modelos.

La dependencia existente entre las observaciones de lluvia diaria consecutivas obliga a considerar extensiones de los GLM que aprovechen su versatilidad en cuanto a la variedad de distribuciones para modelar la respuesta, así como la posibilidad de analizar la influencia de distintas covariables. Las extensiones ensayadas para tratar problemas de dependencia en datos longitudinales o en series de tiempo se clasifican en tres tipos: modelos marginales, modelos condicionales y modelos de efectos aleatorios. Aunque en todas ellas se busca analizar el efecto de las covariables sobre la respuesta, cada una plantea distintos objetivos.

Los modelos marginales, ver la subsección 1.3.2, centran su interés en medir el efecto de las covariables en la variable respuesta, siendo secundario analizar la estructura de relación entre los valores de ésta. Estos modelos no establecen un modelo probabilístico para los datos y sólo proponen una parametrización de la media y de la matriz de varianzas-covarianzas de la respuesta, a partir de las que se define una cuasi-verosimilitud que se usa en el proceso de estimación.

Las otras dos extensiones sí establecen la existencia de un proceso estocástico generador de la serie de respuestas, por lo que se puede construir una verosimilitud del modelo. En los modelos condicionales, subsección 1.3.1, el objetivo radica en analizar el efecto de las covariables sobre la distribución condicionada, dado el valor de las observaciones previas, mediante un modelo de los clasificados como ‘observation driven’. El modelo de efectos aleatorios, subsección 1.3.3, es del tipo ‘parameter driven’ y establece la existencia de un proceso subyacente que provoca la dependencia entre las observaciones.

Se pueden encontrar revisiones y ejemplos del uso de estos modelos en las

monografías de Lindsey (1993) [83] y (1997) [84], Diggle y otros (1994) [37], Fahrmeir y Tutz (1994) [40], Hand y Crowder (1996) [55].

### 1.3.1 Modelos condicionales

Esta extensión se basa en modelar la distribución de la respuesta condicionada a todo su pasado relevante. La idea básica es incluir como covariables los valores retardados de la respuesta necesarios para alcanzar la independencia condicional. De este modo se obtiene una definición del modelo formalmente idéntica a la de un GLM para datos independientes, salvo por el hecho de que se modelan distribuciones y momentos condicionales.

La verosimilitud se construye como un producto que cuenta con un factor por observación, correspondiente a la densidad de probabilidad condicionada al pasado. Las estimaciones MLE se obtienen con el mismo algoritmo usado en el caso de datos independientes y presentan las mismas propiedades asintóticas. Los contrastes de hipótesis habituales pueden aplicarse de la misma forma y, en particular, el análisis del orden de memoria necesario para lograr la independencia condicional se realiza estudiando la significación de las covariables que representan a los distintos retardos de la respuesta, ver Lindsey (1993) [83].

Como caso particular de esta modelización se encuentran los modelos de cadena de Markov, en los que la información pasada relevante constituye el estado de la cadena. En ellos se busca estimar la matriz de probabilidades de transición, lo que equivale a ajustar una distribución multinomial mediante un modelo loglineal. Si la cadena se define con dos estados el ajuste corresponde al de un modelo de regresión logística. Como ejemplo de modelos condicionales en nuestro ámbito de interés se encuentran los modelos markovianos de ocurrencia.

Son también modelos condicionales los de tipo autorregresivo, ya sea con distribución Normal, Gamma, como el ajustado para la cantidad diaria de lluvia por Smith (1994) [107] o, en general, con una distribución de la familia exponencial, Lindsey (1992) [82], (1993) [83].

### 1.3.2 Modelos marginales

Si el interés principal reside en modelar el efecto de las covariables en la variable respuesta, resulta más indicado un modelo donde se expliquen la media y varianza marginales de ésta ya que, a partir de un efecto en el

predictor lineal de un modelo condicional, es difícil deducir la influencia en la esperanza marginal.

La definición de un modelo marginal requiere especificar las siguientes estructuras:

1. Media marginal, ligada mediante una función de enlace con el predictor lineal:

$$E[y_i|\mathbf{x}_i] = \mu_i = g(\mathbf{x}_i^T \beta)$$

2. Función varianza, que establece la relación con la esperanza:

$$Var(y_i|\mathbf{x}_i) = v(\mu_i)\phi$$

3. Función de covarianzas:

$$Cov(y_i, y_{i+r}) = c(\mu_i, \mu_{i+r}, \alpha)$$

donde la función  $c$  establece la relación con las esperanzas marginales y los parámetros adicionales  $\alpha$ .

Con estos elementos se define una cuasi-verosimilitud de la que se deriva una función cuasi-score; la estimación se realiza resolviendo las ecuaciones cuasi-score o GEE (generalized estimating equations). Es habitual que la estructura de correlación no sea conocida, por lo que Diggle y otros (1994) [37] proponen que se empleen en la estimación matrices de correlación de trabajo, que pueden no ser correctas. Las estimaciones de los parámetros del predictor lineal son consistentes y asintóticamente normales; además la estimación mediante GEE es robusta ante una mala especificación de la estructura de covarianza, aunque la estimación de los errores estándar sólo es correcta si la estructura de correlación es la adecuada para los datos.

Distintas monografías han descrito la utilización de este tipo de modelos: Hand y Crowder (1996) [55] muestran el uso de un modelo marginal en el análisis de datos longitudinales y Fahrmeir y Tutz (1994) [40] lo emplean en la modelización de series temporales.

### 1.3.3 Modelos de efectos aleatorios

Este tipo de modelos se ha utilizado para representar la dependencia existente entre observaciones que están agrupadas por alguna característica, relacionada por lo general con el método de medición: si se toman varias observaciones de la misma unidad experimental, como ocurre con los datos longitudinales, Lindsey (1992) [82], (1993) [83], Diggle y otros (1994) [37], Hand y Crowder (1996) [55], o si se trata de observaciones temporalmente próximas en una serie temporal, Fahrmeir y Tutz (1994) [40]. Puesto que hay un efecto asociado a la existencia de diferentes grupos, una opción para modelarlo podría ser la definición de un factor cuyas categorías se correspondieran con ellos; esta estrategia, sin embargo, requeriría un gran número de parámetros, mientras que el modelo de efectos aleatorios resulta mucho más parsimonioso.

Estos modelos son también útiles en problemas donde se presenta sobredispersión, como una alternativa a otras soluciones como el modelo Beta-binomial o el Poisson-gamma, Aitkin y otros (1989) [11], Lindsey (1993) [83]. Se habla de sobredispersión cuando los datos tienen una variabilidad mayor que la que supone el modelo propuesto. En estos casos, el modelo de efectos aleatorios permite representar la existencia de esa heterogeneidad en los datos, asociada a una variable influyente que no se ha medido o no puede obtenerse y cuyo efecto se representa a través de una variable aleatoria que interviene en el predictor lineal.

La definición de la verosimilitud de un modelo de efectos aleatorios se hace en dos etapas. Para un vector respuesta con  $k$  grupos ( $Y_{it}, i = 1, \dots, k, t = 1, \dots, T_i$ ) y dados los coeficientes aleatorios,  $\mathbf{b}_i, i = 1, \dots, k$ , asociados a la matriz de covariables  $\mathbf{W}_{it}$ , las respuestas son independientes. La esperanza, condicionada a dichos efectos aleatorios, está definida por una función de enlace con el predictor lineal que incluye los efectos fijos y los aleatorios:

$$\mu_{it} = E[y_{it}|\mathbf{b}_i] = g(\eta_{it}), \quad \eta_{it} = \mathbf{X}_{it}\beta + \mathbf{W}_{it}\mathbf{b}_i$$

La verosimilitud condicionada a los efectos aleatorios tiene la expresión:

$$L(\mathbf{y}_1, \dots, \mathbf{y}_k | \mathbf{b}_1, \dots, \mathbf{b}_k; \beta) = \prod_{i=1}^k \prod_{t=1}^{T_i} f(y_{it} | \mathbf{b}_i; \beta)$$

En una segunda etapa se establece que los efectos en cada grupo son variables aleatorias independientes con idéntica distribución, dependiente de un vector de parámetros desconocidos,  $Q$ , por lo que la verosimilitud completa incluye los factores correspondientes a la densidad de probabilidad de los efectos aleatorios:

$$L(\mathbf{y}_1, \dots, \mathbf{y}_k, \mathbf{b}_1, \dots, \mathbf{b}_k | \beta, Q) = \prod_{i=1}^k p(\mathbf{b}_i; Q) \prod_{t=1}^{T_i} f(y_{it} | \mathbf{b}_i; \beta)$$

La función de verosimilitud marginal se expresa como un producto de factores, cada uno de ellos correspondiente a la verosimilitud marginal de los datos de un grupo, que se calcula como una integral con respecto a la densidad de los efectos aleatorios:

$$L(\mathbf{y}_1, \dots, \mathbf{y}_k | \beta, Q) = \prod_{i=1}^k \int_{\mathbf{b}_i} p(\mathbf{b}_i; Q) \prod_{t=1}^{T_i} f(y_{it} | \mathbf{b}_i; \beta) d\mathbf{b}_i$$

La estimación en un modelo de coeficientes aleatorios requiere la evaluación de esta verosimilitud marginal utilizando integración numérica.

Un modelo de este tipo, para un problema con respuesta binaria, es el propuesto por Anderson y Aitkin (1985) [14] que usan un enlace logístico y una distribución Normal para los efectos aleatorios. Este modelo es utilizado posteriormente por Collett (1991) [28] y por Fahrmeir y Tutz (1994) [40]. Butler y Louis (1997) [25] plantean una extensión en la que no se impone la distribución Gaussiana.

Fahrmeir y Tutz (1994) [40] presentan un modelo de efectos aleatorios con error binario para analizar la ocurrencia de lluvia diaria en Tokio; en él proponen que la probabilidad de lluvia depende, mediante un enlace logístico, de un predictor lineal que incluye, como término aleatorio, una variable con estructura de dependencia ARMA.



## Capítulo 2

# Validación y control de la bondad de ajuste de los modelos de ocurrencia

### 2.1 Introducción

Como vimos en el capítulo anterior, los modelos de ocurrencia de lluvia basados en cadenas de Markov se pueden ajustar mediante modelos de regresión logística. En ese marco existen herramientas para la crítica y evaluación de los modelos, extensión de las desarrolladas para los modelos lineales, que tienen por objeto detectar posibles insuficiencias del modelo relativas, por ejemplo, a problemas en la escala con la que se introducen las covariables en el predictor lineal, o a identificar observaciones aisladas influyentes o cuyo ajuste es poco adecuado. El artículo de Pierce y Schafer (1986) [95] contiene una revisión de los distintos tipos de residuos definidos en los GLM, así como un análisis de su utilidad según el error de la respuesta. Capítulos dedicados a este aspecto de la modelización se pueden encontrar también en las monografías de McCullagh y Nelder (1989) [89] y en la de Fahrmeir y Tutz (1994) [40].

La respuesta binaria dificulta la crítica de los modelos basada en los residuos, ya que éstos tienen una relación funcional con el predictor lineal; son de signo positivo si la respuesta es 1 y negativo si es 0. Esto provoca que no sean informativas algunas herramientas habituales como su representación frente al predictor lineal o a las distintas covariables, ni que tampoco sea factible la construcción de un qq-plot, al no existir una distribución de referencia bajo la hipótesis de que el modelo es correcto. Se pueden encontrar discusiones a este respecto en monografías dedicadas al análisis de datos binarios como las

de Hosmer y Lemeshow (1989) [58] y Collett (1991) [28].

Por otra parte, los modelos de ocurrencia diaria deben ser capaces de, a partir de las probabilidades ajustadas, reconstruir otras características de la lluvia como, por ejemplo, la distribución de la longitud de las rachas húmedas y secas o la variabilidad observada en la frecuencia anual de días con precipitación.

De todo lo anterior se deduce la necesidad de usar técnicas específicas que permitan conocer las insuficiencias del modelo; esos procedimientos se basan en la comparación de las observaciones con las probabilidades ajustadas y recurren a la simulación cuando la obtención de las características de interés requiere cálculos complejos o es imposible.

En este capítulo se revisan los distintos métodos utilizados en la literatura para la evaluación de modelos de lluvia diaria y, posteriormente, se hace una propuesta sobre los que se utilizarán en el desarrollo de esta memoria.

## 2.2 Métodos de evaluación de modelos de precipitación diaria

Un modelo de precipitación diaria debe ser evaluado analizando su capacidad para representar adecuadamente las características del fenómeno, tanto las calculadas explícitamente en la fase de estimación del modelo (las probabilidades de transición en el caso de una cadena de Markov) como otras derivadas de las observaciones diarias: la reproducción del ciclo anual de frecuencias o la variabilidad interanual, por ejemplo. En particular, los investigadores suelen prestar especial atención a la distribución de la longitud de las rachas secas y húmedas y a que el modelo reproduzca la estructura de autocorrelación observada en la serie de ocurrencia, Buishand (1977) [23].

Klein Tank y Buishand (1995) [77] evalúan su modelo markoviano de ocurrencia usando herramientas, que detallaremos más adelante, basadas únicamente en las probabilidades ajustadas como el estadístico de Hosmer y Lemeshow, el porcentaje de días correctamente clasificados, el porcentaje de días de precipitación por meses e índices como los de Brier, absoluto y relativo, que miden la variabilidad explicada por el modelo.

En modelos simples, como las cadenas de Markov homogéneas, se puede obtener analíticamente las distribuciones de probabilidad de variables como las longitudes de racha. Esto no es posible cuando el modelo es más complejo,

por ejemplo cuando se utilizan covariables continuas, no controladas, en la definición de las probabilidades. En este caso, la simulación permite generar secuencias artificiales a partir de las que se pueden obtener estimaciones de las características de mayor interés, con el fin de compararlas con las correspondientes magnitudes observadas.

Muchos de los modelos comentados en el capítulo anterior han sido evaluados recurriendo a la simulación. Así, Semenov y Barrow (1997) [103] valoran si su modelo reproduce adecuadamente las longitudes de las rachas secas y húmedas a partir de secuencias simuladas de 30 años de longitud, en las que evalúan estadísticos como la longitud media de la racha o el número de días húmedos en un periodo de tiempo dado. Bardossy y Plate (1991) [18] y (1992) [19] o Jimoh y Webster (1999) [70] generan series sintéticas de las que obtienen características como el número de días lluviosos por mes, la estructura de autocorrelación, el número medio de rachas húmedas y secas y la distribución de su longitud. Hay y otros (1991) [56] estudian la capacidad de su modelo, basado en la situación climática reinante, para reproducir la longitud de los periodos secos extremos; para ello realizan 50 simulaciones de 30 años de longitud, de las que obtienen la distribución de la mayor racha seca.

Wilby (1994) [115] valida su modelo de ocurrencia comparando los valores observados y los obtenidos en una simulación de 1000 años de parámetros como la frecuencia global y mensual de lluvia y la distribución de la longitud de las rachas húmedas y secas. Esta comparación se basa en el coeficiente de correlación entre el vector de valores mensuales observado y el calculado en la serie simulada. En su estudio comparativo de modelos para el downscaling de la precipitación, Wilby y otros (1998) [117] evalúan, para cada modelo y en cada estación del año, la frecuencia de la ocurrencia de lluvia en un día, tanto incondicional como condicionada a lo ocurrido en el día anterior, y analizan la media, la desviación típica y el percentil 90 de la distribución de la longitud de racha, seca y húmeda. Para cada una de estas características calculan el coeficiente de correlación entre el vector de valores estacionales observado y el obtenido en la serie simulada.

Zucchini y Guttorp (1991) [126] calculan analíticamente la probabilidad de ocurrencia en un día a partir de su modelo hidden-Markov homogéneo y comparan numéricamente las frecuencias esperadas y observadas en cada estación. El modelo hidden-Markov no homogéneo de Hughes y Guttorp (1994) [66] debe ser simulado para obtener características como la distribución de la longitud de racha húmeda.

Katz y Parlange (1995) [74] estudian, a partir de series artificiales generadas por su modelo para la precipitación horaria, las características correspondientes a periodos de tiempo de mayor amplitud, así como la distribución de la longitud de los periodos secos. Para la evaluación de sus modelos para la precipitación en periodos de 6 ó 15 minutos, Gyasi-Agyei y Willgoose (1999) [54] y Gyasi-Agyei (1999) [53] recurren a la simulación con el fin de extraer estadísticas relativas a intervalos temporales mayores que los básicos, como la frecuencia de periodos secos de 30 minutos, de 1 hora ó 1 día, que son comparadas gráfica y numéricamente con los datos históricos.

Legates y McCabe (1999) [80] critican el uso del coeficiente de correlación para comparar los valores muestrales y los obtenidos mediante simulación, por no ser capaz de diferenciar la relación de identidad de otras situaciones de relación lineal. Por ello introducen dos herramientas complementarias: el coeficiente de eficiencia,  $E$ , y el índice de acuerdo,  $d$ , pero encuentran que estos estadísticos y el coeficiente de correlación discriminan mal entre los modelos: pueden producir en ajustes pobres valores similares a los que proporcionan en ajustes adecuados.

El método habitual de validación consiste en aplicar el modelo a un conjunto de datos adicionales no utilizado en el proceso de estimación; un modelo correcto debe ser capaz de reproducir el comportamiento de datos que pertenecen a la misma población que los usados en el ajuste. Respecto al intervalo de tiempo reservado con este fin, señalaremos que Wilby y otros (1999) [118] ajustan un modelo de ocurrencia con el periodo 1987-1995 y lo validan usando los datos de los años 1981-1986 y que Hughes y otros (1999) [67] estiman un modelo hidden-Markov con los datos de 10 años y reservan un periodo adicional de 5 años para su validación.

## 2.3 Propuesta de evaluación de los modelos de ocurrencia de lluvia

En esta sección se describen las herramientas utilizadas en esta memoria para evaluar los modelos de ocurrencia ajustados. Esta evaluación se hace, en primer lugar, sobre el conjunto de datos empleado en la estimación y, posteriormente, sobre un periodo de registro reservado para la validación del modelo, cuya longitud es una cuarta parte, aproximadamente, del periodo disponible. A ambos conjuntos se aplican las mismas herramientas de crítica. Si el modelo ajustado ha capturado las relaciones esenciales y estables entre la respuesta y las covariables climáticas, la ‘señal’ de lluvia viene expresada

por el valor esperado y las medidas de discrepancia entre éste y los datos observados deben ser semejantes en los dos conjuntos.

Los métodos de evaluación se basan en la comparación de los valores ajustados y observados de la respuesta, bien usando la discrepancia individual, bien de forma agregada en determinados periodos de tiempo. Dada la complejidad de algunos de los modelos ajustados, el análisis de su capacidad para reproducir las características de las secuencias de lluvia se realiza mediante simulación.

### 2.3.1 Métodos que usan las probabilidades ajustadas

Entre los estadísticos de bondad de ajuste conocidos, se han seleccionado aquéllos que, a nuestro juicio, aportan más información sobre las posibles inadecuaciones del modelo. Algunos de ellos son distancias entre los valores observados y ajustados diarios: índices de Brier, porcentaje de días correctamente clasificados y estadístico de Hosmer y Lemeshow; otros constituyen medidas de comparación entre la frecuencia (el porcentaje) de días de lluvia observada en un periodo de tiempo y la correspondiente frecuencia esperada, obtenida mediante la agregación de las probabilidades ajustadas en ese periodo. La comparación se hace usando los coeficientes de correlación, de eficiencia o el porcentaje medio de error.

#### Estadístico de Hosmer-Lemeshow

Hosmer y Lemeshow (1989) [58] proponen un estadístico de bondad de ajuste para modelos de regresión logística que se basa en una tabla de contingencia de dimensión  $2 \times g$ , donde la primera variable corresponde a la respuesta binaria y la segunda a una clasificación en  $g$  categorías, basada en las probabilidades ajustadas de ocurrencia. Los autores proponen dos criterios para realizar la clasificación:

- delimitar las categorías según determinados percentiles de la muestra de probabilidades estimadas: hacer  $g = 10$  usando los deciles, por ejemplo;
- utilizar valores prefijados para definir las categorías; por ejemplo,  $k/g$  con  $k = 1, 2, \dots, g - 1$ .

El estadístico de Hosmer-Lemeshow viene dado por la expresión:

$$\hat{C} = \sum_{k=1}^g \frac{(o_k - n_k \bar{p}_k)^2}{n_k \bar{p}_k (1 - \bar{p}_k)}$$

donde  $n_k$  es el número de observaciones en el grupo k-ésimo,  $o_k$  la frecuencia de respuestas 1 en el mismo grupo y  $\bar{p}_k$  la media de las probabilidades de ocurrencia ajustadas,  $\hat{p}_j, j = 1, \dots, n_k$ ,

$$\bar{p}_k = \sum_{j=1}^{n_k} \frac{\hat{p}_j}{n_k}$$

Bajo la hipótesis nula de que el modelo propuesto proporciona un ajuste adecuado, la distribución del estadístico  $\hat{C}$  es, aproximadamente,  $\chi_{g-2}^2$ . Este comportamiento asintótico se verifica, según los autores, si el número esperado de observaciones en las celdas de la tabla supera el valor 5; para ello, Hosmer y Lemeshow recomiendan definir la clasificación utilizando percentiles. Por otra parte conviene que la clasificación sea suficientemente fina para que el estadístico pueda discriminar adecuadamente; los autores proponen que  $g$  sea al menos 10.

En la memoria se utiliza el estadístico de Hosmer-Lemeshow definido a partir de una tabla  $2 \times 10$ , basada en los deciles de las probabilidades ajustadas.

### Índices de comportamiento de Brier

El índice absoluto de Brier se define como una distancia cuadrática media entre los valores observados de la respuesta y los previstos por el modelo:

$$B = \frac{1}{n} \sum_{j=1}^n (y_j - \hat{p}_j)^2$$

Su interés es menor, pues no está acotado, y sólo es útil para comparar modelos alternativos aplicados a un mismo conjunto de datos.

Resulta más interesante el índice relativo de Brier, que se calcula como un porcentaje de la variabilidad explicada por el modelo propuesto:

$$BR = 100 \left( 1 - \frac{B}{B_c} \right) ; B_c = \frac{1}{n} \sum_{j=1}^n (y_j - \bar{y})^2$$

A diferencia del anterior, este índice permite comparar el grado de ajuste obtenido con modelos aplicados a distintos conjuntos de observaciones, que pueden corresponder a diferentes estaciones del año o provenir de distintos observatorios.

### Porcentaje de días correctamente clasificados

El porcentaje de días correctamente clasificados se basa en una clasificación de cada una de las observaciones de acuerdo con su probabilidad ajustada y en la comparación de su resultado con lo observado.

Cada día se clasifica como previsto-húmedo si su probabilidad ajustada supera 0.5 y como previsto-seco en otro caso. Un día previsto-húmedo está bien clasificado si en él se observa precipitación; análogamente si el día es seco y el modelo lo clasificó como previsto-seco. Este índice se analiza en este trabajo en las 4 situaciones de ocurrencia de precipitación definidas por un día y su víspera, con el fin de valorar la capacidad del modelo para representar la permanencia en un estado y los cambios de racha. El porcentaje de aciertos se analiza globalmente y según la estación del año, con el fin de establecer si el modelo tiene un grado distinto de ajuste en cada época.

Dada la aridez del clima mediterráneo en la región estudiada, con predominio de los días secos y donde es difícil que los modelos ajusten probabilidades superiores a 0.5, nos ha parecido conveniente utilizar otro criterio de clasificación donde el umbral de discriminación esté asociado a la frecuencia de ocurrencia en cada día. El umbral se define como el producto de un factor por la proporción de ocurrencia de lluvia, calculada mediante un suavizado de las frecuencias relativas observadas en cada día; en la memoria se va a utilizar el factor 1. Esta clasificación, respecto de la que utiliza como umbral 0.5, proporciona un mayor número de días previsto-húmedo y disminuye el porcentaje de éxito en la clasificación de días secos, más abundantes.

También debido a las características del clima y para evitar la sobrealoración de la capacidad predictiva del modelo producida por el acierto en la clasificación de los días secos, se calcula el porcentaje sin tener en cuenta los días secos bien clasificados. Este porcentaje, denotado  $\%NAS$ , que se utilizará de forma complementaria, puede considerarse una medida exigente para los modelos, ya que en el cómputo de los éxitos se prescinde de días sin precipitación en los que el modelo ajusta una baja probabilidad de lluvia.

### Porcentaje de días con precipitación

Dos características de gran interés, cuya reproducción por el modelo se va a comprobar, son el ciclo anual de la lluvia y su variabilidad interanual. Para lo primero, se comparan las 12 frecuencias mensuales observadas, expresadas en tanto por ciento, con la media mensual de las probabilidades ajustadas

por el modelo. Análogamente se valoran las diferencias correspondientes a las frecuencias anuales.

Como estos porcentajes se obtienen sobre periodos de datos disjuntos (meses o años), es necesario considerar alguna medida del comportamiento global. Para ello se calcula el coeficiente de correlación entre las series observadas y previstas: valores cercanos a 1 indican que el modelo reproduce el orden observado. Si existe una relación lineal entre los valores observados y ajustados distinta a la identidad, el coeficiente de correlación tomará también valores cercanos a 1; para discriminar estas situaciones se calculan también el coeficiente de eficiencia, el índice de acuerdo y los porcentajes de error.

El coeficiente de eficiencia,  $E_2$ , se calcula mediante la expresión:

$$E_2 = 1 - \frac{\sum_{i=1}^g (o_i - p_i)^2}{\sum_{i=1}^g (o_i - \bar{o})^2} \quad (2.1)$$

donde  $o_i$  y  $p_i$  representan, respectivamente, el estadístico observado y el obtenido a partir de los valores ajustados en el grupo  $i$ . El coeficiente mide la proporción de variabilidad observada que explica el modelo y toma valores entre  $-\infty$  y 1. El valor 1 indica un ajuste perfecto, 0 significa que la variabilidad no explicada coincide con la variabilidad total y valores negativos que la media global representa un ajuste mejor que el proporcionado por el modelo. El coeficiente de eficiencia coincide con el índice relativo de Brier, expresado en tanto por uno y aplicado directamente a las respuestas, haciendo que cada una de las observaciones se considere como un grupo.

La definición del índice de acuerdo,  $d_2$ , viene dada por:

$$d_2 = 1 - \frac{\sum_{i=1}^g (o_i - p_i)^2}{\sum_{i=1}^g (|p_i - \bar{p}| + |o_i - \bar{o}|)^2}$$

Es un índice que varía entre 0 y 1, en el que los mayores valores indican acuerdo entre las magnitudes observadas y ajustadas. Se puede ver como un cociente entre el error cuadrático medio y el error potencial, definido como una suma de cantidades que, para cada grupo, mayoran la distancia  $(o_i - p_i)^2$ .

Los porcentajes de error son medidas relativas que expresan la diferencia entre los estadísticos observados y los valores propuestos por el modelo. El porcentaje medio absoluto de error,  $\bar{E}$ , se define como:

$$\bar{E} = \frac{1}{g} \sum_{i=1}^g \left| \frac{P_0(i) - P_s(i)}{P_0(i)} \right| 100$$

donde  $P_0(i)$  y  $P_s(i)$  son los valores observado y ajustado en el grupo  $i$  y  $g$  el número de grupos definido. El porcentaje medio absoluto de error que evalúa el perfil estacional de la lluvia correspondería, en esa notación, con  $g = 12$ ,  $P_0(i) = o_i$ ,  $P_s(i) = p_i$ .

El porcentaje máximo absoluto de error,  $E_{max}$ , viene definido por la distancia relativa máxima:

$$E_{max} = \max_{i=1, \dots, g} \left| \frac{P_0(i) - P_s(i)}{P_0(i)} \right| 100$$

Para finalizar señalemos que los índices y coeficientes anteriores se usan también en la valoración de los modelos de cantidad de lluvia, sustituyendo las frecuencias por el estadístico correspondiente; por ejemplo, por la media mensual de la cantidad medida en un día con precipitación.

### 2.3.2 Métodos que utilizan simulación

En muchos de los modelos propuestos resulta indispensable estimar mediante simulación las características de la lluvia que se utilizan en la evaluación. En cuanto a la organización del análisis de simulación, número de trayectorias y longitud de las mismas, cabe señalar que los modelos que no incluyen información de otras variables climáticas admiten la posibilidad de simular largas trayectorias; así, Buishand (1977) [23] simula 5 secuencias de 67 años de datos diarios de su modelo de renovación alternante o Gyasi-Agyei y Willgroose (1999) [54] realizan una simulación de 1000 años de su modelo híbrido.

En la literatura se han ido desarrollado a lo largo de la última década, modelos de precipitación que utilizan conjuntos cada vez más complejos de covariables, lo que implica que las trayectorias simuladas puedan tener, a lo más, una longitud igual a la del periodo con observaciones; por otra parte, cuanto mayor es el número y la variedad de variables utilizadas, menor es el periodo de registro disponible. Hughes y Guttorp (1994) [65] estiman la función de supervivencia de las longitudes de rachas mediante la simulación de 1000 trayectorias de 23 años de un modelo hidden-Markov que utiliza sólo la presión atmosférica a nivel del mar. El número de trayectorias simuladas se reduce cuando la información incluida en el modelo es más completa; esto ocurre en los modelos de precipitación basados en la evolución de los estados climáticos reinantes: Hay y otros (1991) [56] analizan 50 trayectorias de una serie de 30 años de longitud, mientras que Bardossy y Plate analizan un número, que no especifican, de series de 34 años, (1991) [18], o de 14, (1992) [19]. Semenov y Barrow (1997) [103] evalúan su modelo, dependiente de la

presión en varios puntos, generando una serie artificial de 30 años. Wilby (1994) [115] señala que, según su experiencia, en los modelos basados en regresión se requiere un número de trayectorias simuladas cuya longitud total esté entre 10 y 20 veces la del periodo de observaciones; en ese mismo artículo simula las réplicas necesarias para alcanzar 1000 años de lluvia diaria, de un modelo estimado con 117 años de datos y, para el análisis particular de los años extremos, simula 20 años de un modelo estimado con los datos de los dos años más secos. Finalmente, Wilby (1995) [116] simula 210 años para un modelo estimado con los datos de 21.

Para los modelos desarrollados en esta memoria se ha optado por simular 20 trayectorias de longitud igual a la del periodo analizado. Esto permite, por ejemplo, obtener 20 conjuntos de rachas húmedas y analizar si la variabilidad de su longitud en un mes corresponde con la observada. Se ha considerado que este número de simulaciones es suficiente para reflejar el comportamiento y variabilidad asociada a los modelos ajustados en los distintos observatorios, que son de dos tipos: termopluiométricos y principales o de primer orden. En el primer caso las covariables disponibles son las temperaturas máxima y mínima diaria, por este motivo se desarrollarán modelos más sencillos, estimados sobre registros diarios de 50 años de longitud, con lo que la variabilidad del proceso se podrá reproducir en trayectorias simuladas largas. En los observatorios de primer orden se tienen medidas de un mayor número de variables atmosféricas, con una longitud de registro menor que los 30 años de un periodo normal. Al construirse modelos con más información, las trayectorias, aun siendo más cortas, permiten analizar una mayor variedad de situaciones y representar aceptablemente la variabilidad del proceso de ocurrencia.

A partir de las series simuladas se pretende analizar tanto la reproducción de la frecuencia de lluvia, como de la persistencia de las rachas de días con precipitación y sin ella. A partir de las series simuladas se calcula:

- la probabilidad marginal de lluvia en un día,
- las probabilidades condicionales de lluvia dada la ocurrencia en el día previo,
- la mediana y el rango intercuartílico de la distribución mensual de la longitud de las rachas secas y húmedas, que tienen un comportamiento asimétrico, y el percentil 90 para valorar la capacidad del modelo en la reproducción de rachas largas.

Para establecer medidas de bondad de ajuste entre los valores obtenidos en la simulación y los observados en distintos grupos de datos, se usa como

distancia el coeficiente de correlación entre las observaciones del valor medio mensual simulado y del correspondiente valor muestral.

La igualdad de distribuciones de la longitud de racha o de la cantidad de lluvia obtenidas por simulación y la distribución muestral se contrasta con los tests de Kolmogorov-Smirnov y de Wilcoxon.



# Capítulo 3

## Modelos condicionales

### 3.1 Introducción

En este capítulo se presentan los modelos de lluvia diaria ajustados en cuatro observatorios de la cuenca del Ebro con distintas características climáticas. Los modelos se componen de una cadena de Markov, para representar la serie binaria de ocurrencia, y de un modelo para la cantidad de lluvia registrada en los días con precipitación positiva. Ambos submodelos, que se van a construir en el marco de los GLM, son de tipo condicional y relacionan la variable respuesta con su propia memoria, el patrón estacional y las covariables disponibles en el observatorio: temperatura, presión atmosférica, humedad, viento en superficie o información sobre la situación en la troposfera.

La sección 3.2 se dedica a revisar las características de la precipitación en los observatorios analizados que, además de presentar diferencias climáticas, disponen de diferente información. En la sección 3.3 se presenta el modelo de ocurrencia elegido, se analiza su interés frente a otras alternativas y se describe la metodología seguida para su ajuste y validación.

A lo largo de las secciones 3.4 a 3.7 se analizan las características, validez y grado de ajuste de las cadenas de Markov estimadas. En cada observatorio se ajusta una cadena homogénea, una estacional, cuya matriz de probabilidades de transición cambia para cada día del año, y modelos que incorporan, además, la información de variables atmosféricas.

La sección 3.8 proporciona una visión final del proceso de modelado de la ocurrencia de lluvia donde se resumen los resultados alcanzados y se hace un análisis comparativo de la estructura de los predictores y del comportamiento de los modelos.

	Altitud	Latitud	Longitud	Periodo disponible
Reinosa	855m	43° 0' 4" N	4° 8' 17" W	1912-1975/1985-1994
Agoncillo	352m	42° 27' 6" N	2° 19' 51" W	1978-1997
Zaragoza-Aer.	240m	41° 39' 43" N	1° 0' 29" W	1990-2000
Tortosa	50m	40° 49' 14" N	0° 29' 29" E	1942-1991

Tabla 3.1: Posición geográfica de los observatorios y periodo de registro utilizado.

Para ajustar las cantidades se han utilizado GLM con error Gamma que asocian a cada día del año, un valor esperado de la precipitación registrada en caso de lluvia, dependiente de la posición del día o del valor que toman diversas covariables climáticas. En la sección 3.9 se hace una revisión de la literatura y de nuestros trabajos sobre este tipo de modelos; los modelos ajustados en los cuatro observatorios y el análisis de sus insuficiencias se presentan en la sección 3.10.

El capítulo finaliza con la sección 3.11 donde se exponen las líneas de investigación abiertas y algunas propuestas para la continuación de nuestro trabajo de modelización.

Todos los modelos propuestos se sitúan dentro del marco de los GLM. Para estimarlos se ha usado GLIM 4.0 y S-plus en su versión 4.5.

## 3.2 Observatorios analizados

Se han utilizado como datos las mediciones de la lluvia registrada en una estación meteorológica en intervalos de 24 horas. Este tipo de registro es el más frecuente en los observatorios del INM (Instituto Nacional de Meteorología) y está disponible en la cuenca del Ebro para una densa red de estaciones. Para considerar un día lluvioso, se ha establecido el umbral de 1 décima de litro, coincidiendo con la resolución de registro del INM.

El Centro Meteorológico Territorial de Aragón, La Rioja y Navarra proporcionó los datos de los observatorios de Reinosa (Cantabria), Agoncillo (La Rioja), Zaragoza-aeropuerto y Tortosa (Tarragona). Al seleccionar estos observatorios se ha pretendido aplicar los modelos a distintos regímenes de precipitación dentro de la cuenca del Ebro. En la tabla 3.1 se muestra la situación geográfica de esos observatorios y los periodos de registro utilizados, mientras que en la tabla 3.2 y en la figura 3.1 aparecen los valores medios de la cantidad de lluvia anual y mensual, relativos al periodo 1961-1990, extraídos de Almarza y otros (2000) [13].

	Reinosa	Agoncillo	Zaragoza	Tortosa
Enero	96.0	27.5	22.7	32.8
Febrero	98.8	25.1	21.2	33.4
Marzo	78.2	30.0	22.7	31.0
Abril	99.3	43.4	32.9	45.7
Mayo	77.0	46.8	38.0	62.3
Junio	46.4	44.3	31.5	36.9
Julio	31.1	22.8	15.3	13.6
Agosto	32.0	21.6	16.6	36.5
Septiembre	50.6	28.0	26.3	70.8
Octubre	83.7	28.1	29.8	92.3
Noviembre	114.9	39.5	36.2	60.3
Diciembre	125.2	30.5	21.0	42.5
Anual	933.2	387.6	314.2	558.1

Tabla 3.2: Valores medios de la precipitación acumulada, en litros/m<sup>2</sup>, en el periodo normal 1961-1990, Almarza y otros (2000) [13].

Las figuras 3.2 y 3.3, que muestran la evolución anual del valor medio de la frecuencia relativa de ocurrencia y de la cantidad registrada cuando llueve, ayudan a valorar las diferencias en cada observatorio. Se puede destacar que:

- Reinosa representa el régimen más lluvioso de los cuatro estudiados y tiene un clima de tipo atlántico, caracterizado por la existencia de una única estación seca, el Verano. Los otros tres observatorios presentan características del clima mediterráneo: la existencia de dos estaciones secas, Invierno y Verano, y dos húmedas, ver figura 3.1.
- Agoncillo se encuentra situado en la parte occidental del Valle Medio y, por su posición geográfica, es un observatorio de transición entre las dos áreas climáticas citadas; como consecuencia, la frecuencia de días con precipitación refleja un mínimo relativo invernal menos marcado que el de Zaragoza, véase la figura 3.2.
- Zaragoza tiene un clima mediterráneo-continental y es el lugar más árido de los cuatro estudiados; su frecuencia relativa de lluvia es menor que en Agoncillo y la media de la cantidad acumulada anual durante el periodo normal 1961-1990 es 73 litros menor, ver tabla 3.2. En comparación con Tortosa, su frecuencia de días húmedos es semejante; la diferencia en la cantidad media asociada a los días de lluvia en Tortosa, mayor durante todo el año, explica la mayor cantidad acumulada anualmente en este lugar, ver figura 3.3.

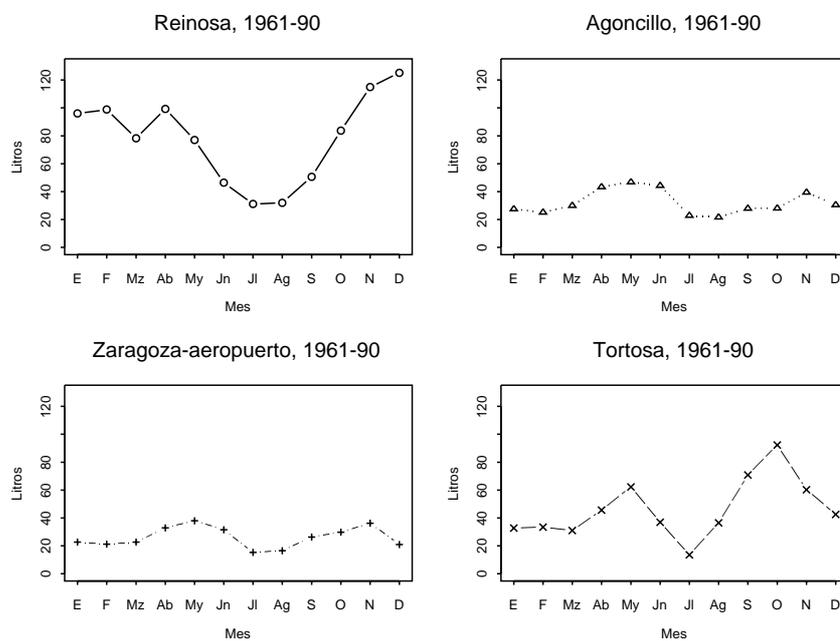


Figura 3.1: Valores medios de la precipitación acumulada mensual en el periodo 1961-1990, Almarza y otros (2000) [13].

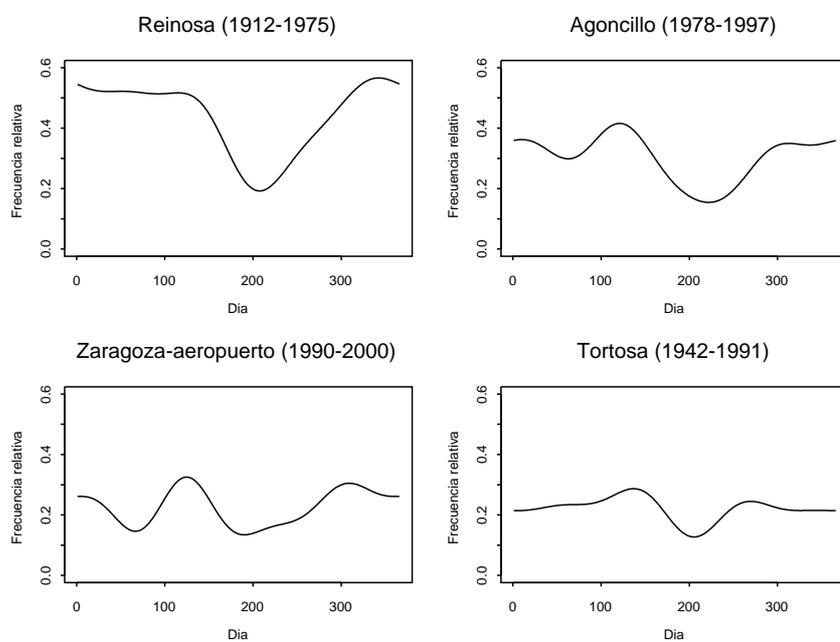


Figura 3.2: Valores suavizados de la frecuencia diaria de ocurrencia de precipitación.

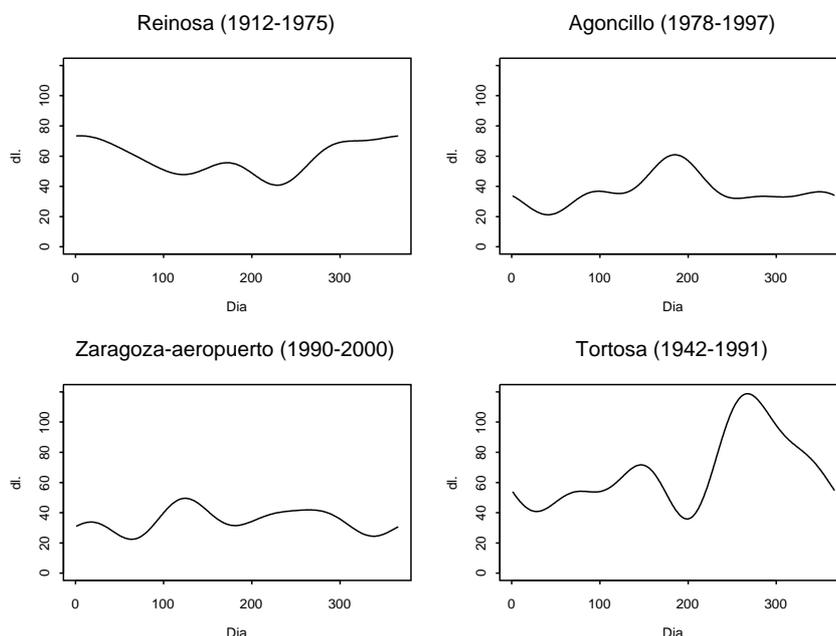


Figura 3.3: Valores suavizados de la cantidad media registrada en días con precipitación.

- Tortosa, situada en la desembocadura del Ebro, representa el clima mediterráneo litoral. Una diferencia importante entre su régimen de precipitación y el de los otros observatorios radica en la mayor frecuencia de precipitaciones extremas en el inicio del Otoño, asociadas a la situación denominada de ‘gota fría’, ver figura 3.3. Este hecho se refleja en la tabla 3.3 que muestra la frecuencia de días con lluvia superior a distintos umbrales; para evitar el efecto de la distinta longitud de registro y facilitar la comparación, se indica, entre paréntesis, la frecuencia por año observado.

En un trabajo desarrollado para la Confederación Hidrográfica del Ebro, García-Vera y otros (2002) [44], Abaurrea y otros (2002) [10], se estableció una regionalización de la cuenca del Ebro basada en el patrón de evolución temporal en el periodo 1916-2000. Se trabajó a partir de 29 series homogeneizadas de lluvia anual, entre ellas los cuatro observatorios estudiados en este capítulo. En la figura 3.4, procedente de ese trabajo, se observa cómo cada uno de los observatorios estudiados se sitúa en una zona distinta de las delimitadas a lo largo del río.

La selección de los observatorios atendió, además de a la variedad climática, a un criterio de calidad de las mediciones. Este requisito lo verificaban,

litros/m <sup>2</sup>	Reinosa	Agoncillo	Zaragoza	Tortosa
30	307 ( 4.8 )	14 ( 0.7 )	6 ( 0.5 )	206 ( 3.9 )
40	135 ( 2.1 )	5 ( 0.2 )	2 ( 0.2 )	112 ( 2.1 )
50	53 ( 0.8 )	3 ( 0.2 )	0 ( 0 )	76 ( 1.4 )
60	25 ( 0.4 )	1 ( 0 )	0 ( 0 )	50 ( 0.9 )
70	13 ( 0.2 )	0 ( 0 )	0 ( 0 )	31 ( 0.6 )
80	6 ( 0.1 )	0 ( 0 )	0 ( 0 )	22 ( 0.4 )
90	2 ( 0 )	0 ( 0 )	0 ( 0 )	13 ( 0.2 )
100	1 ( 0 )	0 ( 0 )	0 ( 0 )	9 ( 0.2 )
110	0 ( 0 )	0 ( 0 )	0 ( 0 )	7 ( 0.1 )
120	0 ( 0 )	0 ( 0 )	0 ( 0 )	5 ( 0.1 )
130	0 ( 0 )	0 ( 0 )	0 ( 0 )	3 ( 0.1 )

Tabla 3.3: Frecuencia de grandes precipitaciones en los observatorios estudiados; entre paréntesis, frecuencia media anual.

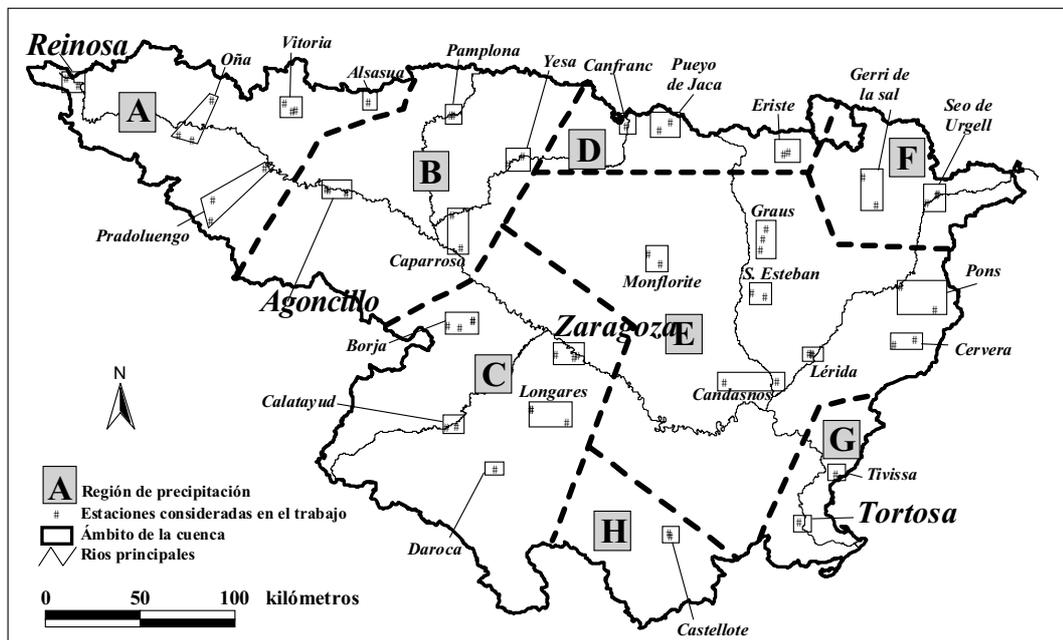


Figura 3.4: Mapa de la cuenca del Ebro y regiones con una evolución temporal homogénea de la precipitación anual, Abaurrea y otros (2002) [10].

a priori, los observatorios de Zaragoza-aeropuerto y de Agoncillo, que están bajo la responsabilidad de observadores profesionales. Reinosa y Tortosa cuentan con un largo periodo de registro, no han sufrido alteraciones ni experimentado un desarrollo urbano notable en el periodo de estudio y, en el momento de su selección, sus mediciones eran consideradas fiables por los técnicos del Centro Territorial del INM en Zaragoza. Por otra parte, en el trabajo de Almarza y otros (1996) [12], donde se estudia la homogeneidad de las 50 series españolas de precipitación más prolongadas, entre ellas las de Tortosa, Logroño y Zaragoza, se concluye que no existen signos de inhomogeneidad en los registros de estos tres observatorios durante los intervalos temporales que se estudian en la memoria.

Tras el trabajo citado de Abaurrea y otros (2002) [10], en donde se analizó la homogeneidad de las series acumuladas anual y estacionalmente, utilizando el procedimiento propuesto por Moberg y Alexandersson (1997) [90], se dispone de información complementaria. En las series de Zaragoza y Tortosa no se encontraron inhomogeneidades significativas; en Reinosa y Agoncillo se detectaron sendas inhomogeneidades en el Invierno.

### **Variables utilizadas**

La base de datos del INM dispone de series prolongadas de valores diarios de precipitación y temperatura máxima y mínima. La utilización de otras variables climáticas implica una reducción de la longitud del periodo de análisis puesto que sus medidas comienzan en épocas relativamente recientes. Por ello, ver tabla 3.1 en la página 32, los datos utilizados en cada observatorio corresponden a distintos intervalos de tiempo; en el observatorio de Agoncillo se han utilizado medidas de presión atmosférica y en el del aeropuerto de Zaragoza información proporcionada por radiosondeos, sólo desde 1990.

### 3.3 Modelos de cadena de Markov para la ocurrencia de precipitación

La línea seguida para la construcción de modelos en este capítulo, se basa en la propuesta por Stern y Coe (1984) [108], modificada posteriormente por otros autores, ver capítulo 1. En esencia, Stern y Coe plantean la estimación de las probabilidades de transición al estado húmedo en una cadena con memoria de orden  $k$ , como el ajuste de un modelo de regresión logística. Para cada día  $t$  del año se calcula el número de ocasiones en las que se ha registrado precipitación (lo que corresponderá al número de éxitos) dentro del conjunto de observaciones que se hallan en unas determinadas condiciones según la ocurrencia de lluvia pasada ( $2^k$  situaciones posibles), lo que corresponde al número de ensayos. Cada una de las probabilidades de transición al estado 1 se ajusta mediante un modelo de regresión que incluye en el predictor lineal armónicos de un desarrollo en serie de Fourier, para que las probabilidades reflejen el comportamiento estacional de la lluvia. La inclusión de estos armónicos reduce considerablemente el número de parámetros del modelo, respecto al necesario si se ajustasen parámetros específicos para cada día del año.

El inconveniente al trabajar de esta forma es que, si el orden de memoria es grande, puede haber días del año y situaciones de ocurrencia en las que haya pocas o ninguna observación. Esto plantea dificultades tanto en el proceso de estimación como en la fase de comparación de modelos. Para evitarlas, Stern y Coe consideraron constantes los parámetros en grupos de 5 días con lo que, para cada probabilidad de transición, ajustaron 73 en lugar de 365 respuestas.

Modelos de este tipo fueron ajustados en Abaurrea, Asín y Cebrián (1994) [1]. El primer paso en la modelización consiste en reconocer el orden adecuado de la cadena; para ello se desarrollaron procedimientos que permiten analizar el modelo de orden  $k$  anidado en el correspondiente de orden  $k + 1$ . A partir del mejor modelo del orden seleccionado, se efectúa un proceso de simplificación en el que se decide la posibilidad de considerar idénticas las probabilidades de transición correspondientes a algunas situaciones.

Klein Tank y Buishand (1995) [77] proponen un modelo de cadena de Markov en el que la respuesta binaria se relaciona con valores retardados de ella misma, armónicos y covariables climáticas de tipo continuo. La adición de estas últimas hace imposible considerar una agrupación de días según las situaciones experimentales definidas por las covariables ya que, en cada una

de ellas, hay habitualmente una sola observación.

Este tipo de modelización, utilizada en los trabajos de Abaurrea y Asín (1997) [3], (1997) [4] y (1999) [5], presenta ventajas sobre el esquema propuesto por Stern y Coe. Es evidente que los modelos, al incluir más información, van a ajustar mejor la respuesta; por otra parte, la estimación conjunta de las distintas probabilidades condicionales permite una rápida búsqueda del orden de la cadena. El inconveniente de trabajar en un esquema de respuesta binaria, en lugar de en uno binomial, es la ausencia de procedimientos basados en residuos para efectuar la crítica de los modelos.

En comparación con otros tipos de modelo de ocurrencia, cabe señalar que las cadenas de Markov suponen un marco de modelización más versátil que el proceso de renovación alternante, la alternativa más utilizada. Abaurrea, Asín y Cebrián (1994) [1], (1995) [2], desarrollaron modelos de ese tipo utilizando una distribución Binomial Negativa, cuyos parámetros dependían del tipo de racha y de la época del año, para representar las longitudes de racha.

Este modelo puede resultar competitivo si no se incluye información de otras covariables climáticas pero es menos adaptable que las cadenas de Markov, que ajustan una probabilidad para cada día observado. En particular, cualquier método de asignación de los valores de una covariable a una racha de longitud mayor que 1, implica una pérdida de información. La dificultad en solucionar este problema complica la simulación del modelo y, en consecuencia, el ‘downscaling’ estadístico en una situación de cambio climático.

La ausencia de covariables climáticas distintas de la temperatura en algunos observatorios y el hecho de que los modelos de ocurrencia no resultaban satisfactorios en la predicción de la llegada de una racha húmeda, nos llevó a considerar que una de las causas de ese desajuste era la falta de información en el modelo sobre la situación climática reinante. La serie temporal de los estados climáticos sobre la Península Ibérica no ha sido, todavía, definida explícitamente, por lo que no pueden aplicarse modelos como los propuestos por Goodess (2000) [50] en Inglaterra o por Bardossy y Plate (1991) [18] en Alemania.

Tratando de paliar esa ausencia, Abaurrea y Asín (1999) [5] ajustaron modelos de efectos aleatorios, Generalized Linear Mixed Models (GLMM), a las series diarias de ocurrencia de Reinos y Tortosa. Estos modelos suponen la existencia de un efecto de valor desconocido ligado a un factor que representa la permanencia de una situación climática en varios días consecutivos. Aunque los modelos mejoraban relativamente la previsión del cambio de ra-

cha, seguían sin ser satisfactorios, entre otras causas, porque la definición de los grupos de días sometidos al mismo efecto se hacía únicamente a partir de la información de la temperatura.

Las cadenas de Markov ocultas permiten modelar una estructura estocástica subyacente que refleje la evolución de los estados atmosféricos. En los trabajos de Abaurrea y Asín (1999) [6] y (1999) [7] se ensayaron modelos hidden-Markov no homogéneos para analizar la ocurrencia de lluvia en Agoncillo, que dieron lugar a ligeras mejoras respecto al ajuste obtenido con la cadena de Markov.

Este tipo de modelización basada en estados climáticos, ya sean definidos explícitamente o subyacentes, interesante desde el punto de vista teórico, pierde interés práctico si se dispone de una información climática más completa que represente cuantitativamente la situación atmosférica. En la actualidad, esa información exhaustiva está disponible en la forma de datos provenientes de ‘reanálisis’; en estas condiciones, los modelos más complejos de esta memoria, ajustados para los datos medidos en el aeropuerto de Zaragoza, con su propio radiosondeo, podrían adaptarse a cualquier observatorio.

El resto de esta sección se dedica a presentar el tipo de cadenas de Markov que se van a ajustar, a establecer los criterios seguidos para su construcción y, finalmente, a describir las herramientas de crítica que se aplican en su validación.

### 3.3.1 Esquema y criterios seguidos en el proceso de ajuste del modelo de ocurrencia

La respuesta en el día  $t$ , denotada  $Y_t$ , es una variable binaria que indica la ocurrencia de precipitación: toma el valor 0, que corresponde al estado ‘seco’, si la cantidad de lluvia registrada es inferior a 0.1 litros/m<sup>2</sup> y el valor 1 en otro caso. El modelo de regresión logística estima la probabilidad de ocurrencia de lluvia en el día  $t$ ,  $P(Y_t = 1|Y_{t-1}, Y_{t-2}, \dots, Y_{t-k}, \mathbf{X}_t)$ , condicionada a la información que proporciona la memoria del proceso y las distintas covariables, representadas por el vector  $\mathbf{X}_t$ , que contiene las medidas del día  $t$  y toda la información retardada de interés.

La propiedad de Markov requiere la inclusión en el predictor lineal de la información correspondiente a los días previos, hasta el retardo necesario para que las respuestas, en días separados más de esa distancia, sean condicionalmente independientes. La probabilidad de transición al estado representado por el vector  $(Y_{t-k+1}, Y_{t-k+2}, \dots, Y_{t-1}, Y_t = 1)$  desde el estado  $(Y_{t-k}, Y_{t-k+1}, \dots, Y_{t-1})$ , en las condiciones dadas por las covariables  $\mathbf{X}_t$ , es idéntica a la probabilidad condicionada de ocurrencia de lluvia:

$$\begin{aligned} P(Y_t = 1|Y_{t-1}, Y_{t-2}, \dots, Y_{t-k}, \mathbf{X}_t) &= \\ &= P(Y_{t-k+1}, Y_{t-k+2}, \dots, Y_{t-1}, Y_t = 1|Y_{t-k}, Y_{t-k+1}, \dots, Y_{t-1}, \mathbf{X}_t) \end{aligned}$$

El modelo de regresión logística asociado proporciona la caracterización del proceso de ocurrencia: las covariables incluidas en el predictor lineal se pueden interpretar como la información relevante para establecer la probabilidad de ocurrencia en las condiciones existentes. Los efectos asociados a las covariables reflejan la importancia y el sentido de su relación con la respuesta.

Se han construido modelos con diferente grado de información que incluyen en el predictor lineal covariables de distinto tipo. Se pretende valorar el grado de mejora que logran los modelos con mayor nivel de información respecto a los más simples. En cada observatorio se ajusta:

- Una cadena de Markov temporalmente homogénea en cuyo predictor sólo aparecen indicadores de la ocurrencia pasada; nos referiremos a este modelo con la notación *CM hom*.
- Una cadena de Markov no homogénea, que se denota *CM est*, cuya matriz de probabilidades de transición recoge el comportamiento estacional del fenómeno mediante la inclusión en el predictor lineal de armónicos de un desarrollo en serie de Fourier.

- Una cadena de Markov que incorpora, además, información sobre las temperaturas máxima y mínima diaria, a la que se cita como *CM temp*. Se han tomado como variables predictoras la temperatura mínima, denotada  $TMIN_t$ , y el rango diario ( $TDIF_t$ ), definido como la diferencia entre la temperatura máxima y la mínima.
- En Agoncillo se ajustan también modelos que consideran la información sobre la presión atmosférica. Para el aeropuerto de Zaragoza se estiman modelos que incluyen la información registrada en superficie: temperatura, presión, humedad y viento, y otros que, además, utilizan variables medidas en la troposfera.

### Construcción de los modelos

El objetivo genérico de la modelización estadística es explicar la mayor parte de la variabilidad observada con la estructura más simple posible. En la construcción de los modelos se ha pretendido que la estructura del predictor lineal sea susceptible de interpretación desde el punto de vista meteorológico, lo que implica el uso de las variables originales o de transformaciones simples, por lo que se ha descartado recurrir a técnicas de reducción de la dimensión en la matriz de covariables.

Dada la gran cantidad de covariables de interés que pueden definirse a partir de la información disponible, en algunos observatorios, Zaragoza es el caso extremo, no resulta factible ensayar todos los modelos posibles. Por ello, se ha aplicado una estrategia consistente en la construcción de un modelo completo, siguiendo los criterios que se explican más adelante, en el que se incluyen sucesivamente covariables que implican una mejora significativa del grado de ajuste. Sobre ese modelo se desarrolla posteriormente una fase de eliminación de términos no significativos. Se ha trabajado, en general, con un nivel de significación de 0.05 y se ha utilizado el nivel 0.01 para eliminar los términos de un armónico cuando no resultaba significativo alguno de orden inferior.

El proceso de modelado consiste en la formulación y estimación reiterada de modelos y en el contraste de lo que proponen con los datos. Los sucesivos modelos se comparan para decidir cuál es el más adecuado. La comparación se establece entre modelos anidados, es decir, hay un modelo más complejo cuya estructura lineal contiene la del más simple.

El modelo complejo explica más variabilidad y tiene menor ‘deviance’ o desviación, medida de bondad de ajuste usada en el marco de los GLM, pero

utiliza más parámetros. Para valorar si el modelo simple debe ser preferido, el test compara la disminución de deviance con una distribución  $\chi^2$  cuyos grados de libertad corresponden al número de parámetros adicionales que contiene el modelo complejo.

Las fases para alcanzar el modelo más completo son las siguientes:

- La construcción de un modelo condicional requiere la introducción en el predictor lineal de toda la información relevante del pasado, lo que se lleva a cabo incluyendo retardos de la propia respuesta hasta que no se obtiene una disminución significativa de la desviación. Cuando se introduce una variable binaria, se analiza en primer lugar si existe un efecto principal y, posteriormente, si son necesarios términos de interacción con cada uno de los retardos ya incluidos.
- Para reflejar el carácter estacional del fenómeno, los valores medios se hacen depender de covariables que reflejan la periodicidad anual, concretamente de términos seno y coseno de los armónicos de un desarrollo de Fourier. Se denotan  $S_i t$  y  $C_i t$  a las variables seno y coseno correspondientes al armónico  $i$ -ésimo en el día  $t$ ; esto permite modelar configuraciones periódicas complejas con pocos parámetros.

El proceso de modelización parte del modelo homogéneo obtenido y busca el número de armónicos más adecuado para caracterizar el ciclo anual de la ocurrencia de lluvia. Se comienza analizando la necesidad de incluir el primer armónico y, sucesivamente, se incorpora en cada ocasión uno nuevo, hasta que la disminución en desviación deja de ser significativa. Finalmente, se analiza la significación de los términos de interacción de los armónicos introducidos con los indicadores de ocurrencia de lluvia presentes.

- En último lugar se analiza la inclusión en el predictor de las covariables climáticas disponibles. Partiendo del modelo estacional se estudia para cada una de ellas la significación del efecto lineal y, si éste es significativo, el interés de introducir un efecto cuadrático. Posteriormente se considera la interacción de estos efectos con los marcadores binarios de ocurrencia que se encuentran en el predictor. Este proceso de análisis se lleva a cabo también para estudiar el efecto de la covariable en el día previo; si éste es significativo, se analiza el efecto de retardos adicionales.

Tras alcanzar el modelo más completo, el proceso requiere una fase de simplificación de los términos no significativos; el orden en que se realiza

viene dado por el valor absoluto del estadístico  $t$  correspondiente a cada término. Se sigue el criterio de no prescindir de un término lineal cuando es significativo su término cuadrático y tampoco se eliminan términos seno o coseno de un cierto armónico si son significativos los de un orden igual o superior.

### Crítica de los modelos

En el proceso de construcción de modelos de regresión el análisis de residuos es un medio útil para detectar posibles deficiencias del modelo, para identificar la existencia de efectos de interés que no han sido considerados y, en general, para informarnos sobre el modo de mejorar el modelo. Sin embargo, como se ha comentado en el capítulo anterior, los residuos no son útiles en los modelos con respuesta binaria, por lo que la crítica de los modelos se lleva a cabo con las herramientas que se indican a continuación.

Para cada modelo estimado se construye una tabla que permite evaluar, desde distintos aspectos, la bondad de ajuste así como comparar modelos no anidados. Esta tabla incluye:

- Medidas como el AIC y BIC, que consideran la verosimilitud del modelo y penalizan el número de parámetros utilizados.
- La autocorrelación de orden 1 de los residuos de la deviance cuya significación y comparación con el valor correspondiente en la serie de observaciones, permite valorar si el modelo condicional ha captado la dependencia temporal existente.
- El estadístico de Hosmer y Lemeshow para contrastar la hipótesis de que el ajuste es globalmente adecuado.
- Medidas que permiten valorar el grado de ajuste y comparar modelos no anidados, como:
  - El porcentaje de variabilidad explicada de la respuesta.
  - Los porcentajes de días correctamente clasificados utilizando como umbrales el valor 0.5 y la frecuencia relativa correspondiente a ese día. Este porcentaje se analiza por estaciones: Primavera (Marzo-Abril-Mayo), Verano (Junio-Julio-Agosto), Otoño (Septiembre-Octubre-Noviembre) e Invierno (Diciembre-Enero-Febrero) y de acuerdo con lo ocurrido cada día y su víspera. Se calcula también el porcentaje de días bien clasificados sin considerar los éxitos en la previsión de días secos, que se denota %NAS.

- Los coeficientes de correlación y de eficiencia, el índice de acuerdo y el porcentaje medio de error, definidos a partir del número de días con precipitación, observados y ajustados, por meses y por años.

Para completar esta información se dibujan los correlogramas de la serie de la variable respuesta y de la de residuos de la deviance, así como gráficos que permiten comparar la frecuencia relativa observada, por meses o anualmente, con la frecuencia relativa esperada, calculada a partir de las probabilidades ajustadas.

El interés por valorar la reproducción que hace el modelo de la distribución de la longitud de las rachas secas y húmedas ha hecho que incluyamos una tabla en la que se comparan los percentiles de dichas distribuciones, en cada mes, con los obtenidos a partir del modelo, bien de forma analítica, bien mediante simulación. En este último caso, se realizan gráficos para comparar los percentiles observados, mediana y percentil 90, con los obtenidos en cada una de las simulaciones generadas, lo que permite comprobar si aquéllos se encuentran en el rango definido por éstos.

Todas las tablas y gráficos citados se han construido tanto para el conjunto de datos de estimación como sobre el reservado para la validación del modelo.

## 3.4 Modelos para la ocurrencia de precipitación en el observatorio de Tortosa

Tortosa se encuentra situada en la desembocadura del Ebro, entre el delta y la Cordillera Costera Catalana. Las características de la precipitación en este observatorio son las de un clima mediterráneo, con una frecuencia relativa de ocurrencia de lluvia que oscila alrededor de 0.2, véase la figura 3.2.

En este observatorio se dispone de la información diaria sobre la precipitación acumulada y las temperaturas máxima y mínima. En la memoria se han utilizado sus datos desde 1942 a 1991; la estimación de los modelos se ha hecho con los registros de los años 1942 a 1981 y se ha reservado el periodo 1982-1991 para su validación.

Las cadenas de Markov ajustadas, incluyendo una valoración de los efectos contenidos en sus predictores, se presentan en la subsección 3.4.1. En la 3.4.2 se discute la capacidad de cada uno de los modelos para reproducir distintos aspectos de la distribución de ocurrencia, reservando la subsección 3.4.3 para el análisis específico de la distribución de las longitudes de racha. Esta sección finaliza con una evaluación del comportamiento de los modelos en el periodo de validación.

### 3.4.1 Modelos ajustados

En las tablas A.1 y A.2 del volumen anexo aparecen los efectos que resultan estadísticamente significativos en los modelos *CM hom*, *CM est* y *CM temp*; los términos de interacción entre dos variables se representan con el nombre de las mismas separados por dos puntos.

El orden de memoria requerido en estos tres modelos es 4. El efecto de los distintos retardos es positivo y, por lo tanto, indica un incremento de la probabilidad de lluvia si ocurre precipitación en los días previos. Este efecto es menor cuanto más antiguo es el retardo y no tiene carácter aditivo: el incremento asociado a la ocurrencia de lluvia en los días  $t-2$  y  $t-3$  se anula por su interacción con la ocurrencia en el día  $t-1$ . El efecto de los retardos y de sus interacciones es semejante en los tres modelos; el único cambio relevante se produce en *CM temp* con el coeficiente de  $Y_{t-1}$ , que mantiene el signo, debido a su interacción con el rango de temperatura.

Los armónicos recogen el doble ciclo que se observa en la probabilidad de ocurrencia a lo largo del año. Su efecto experimenta cambios notables

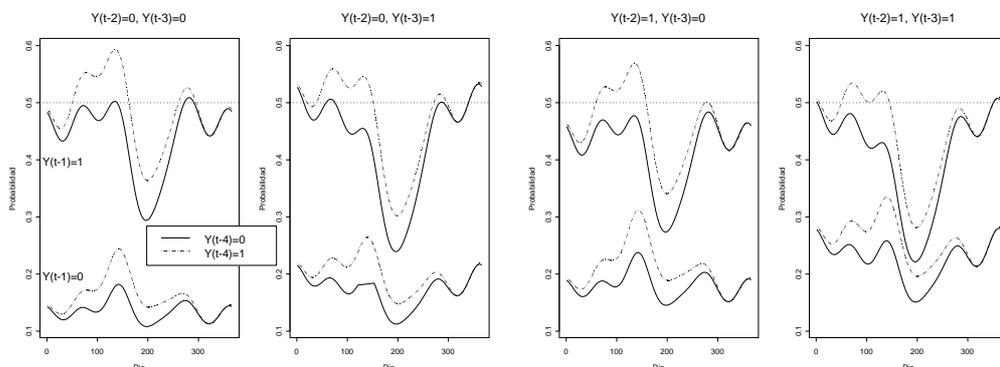


Figura 3.5: Probabilidad de lluvia ajustada por *CM est* en Tortosa en las distintas situaciones de ocurrencia previa.

dependiendo de la ocurrencia en los días previos; en la figura 3.5 se presentan las 16 curvas ajustadas por la cadena de Markov estacional y se aprecia la gran influencia que ejerce la ocurrencia en el día anterior.

La adición de armónicos al modelo homogéneo supone una disminución en la deviance pequeña (90) comparada con la que produce la inclusión de información de temperatura en el modelo estacional (1170). La información acerca de la temperatura diaria en los modelos de lluvia puede parecer a priori poco relevante, ya que es un hecho que llueve cuando hace frío y cuando hace calor; sin embargo, el efecto significativo de las covariables de temperatura ha sido observado también por Buishand y Klein Tank (1996) [24], Brandsma y Buishand (1997) [22].

El rango diario resulta la covariable más relevante. Su coeficiente negativo se explica por la asociación de la lluvia con la presencia de nubosidad: una menor irradiación durante las horas diurnas induce menores temperaturas máximas, mientras que, durante la noche, las nubes ralentizan la disipación del calor acumulado a lo largo del día, por lo que la temperatura en superficie desciende menos que cuando está despejado. Ambas circunstancias implican una disminución del rango diario de temperatura.

En el predictor del modelo *CM temp* aparece información sobre el rango de temperatura y la temperatura mínima en el mismo día y en el día precedente. El efecto del rango es lineal y negativo si el día previo es seco y cuadrático cuando se produce precipitación en el día anterior, véase la figura 3.6. La temperatura mínima del propio día tiene un efecto negativo y la del día anterior uno positivo, aunque su valor absoluto se reduce a la mitad.

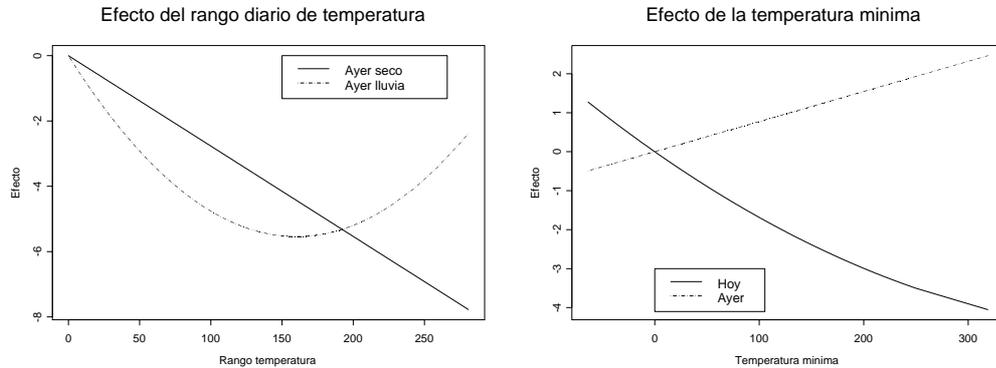


Figura 3.6: Ajuste de *CM temp* en Tortosa. Izda.: Efecto del rango diario de temperatura ( $10^{-1}$  °C). Dcha.: Idem de la temperatura mínima ( $10^{-1}$  °C).

### 3.4.2 Bondad de ajuste

En las tablas A.3, A.4 y A.5 aparecen medidas del grado de ajuste que presentan cada uno de los tres modelos. En el caso del modelo homogéneo no se calcula el estadístico de Hosmer-Lemeshow porque el número de probabilidades ajustadas distintas,  $2^4$ , es demasiado pequeño.

Se puede concluir que el mejor ajuste es el de *CM temp* y que el modelo estacional no representa una mejora importante respecto del modelo homogéneo. Señalemos algunos puntos de interés:

- Los modelos homogéneo y estacional explican la misma proporción de variabilidad, tanto anual como estacionalmente. Únicamente cabe destacar la mejora en el índice relativo de Brier que se obtiene con *CM est* en el Verano.
- El porcentaje de variabilidad explicada por *CM temp*, un 18.8%, duplica el de los otros dos modelos. Al ordenar las estaciones según el valor del índice relativo de Brier, se observa que el modelo se comporta mejor en Primavera (24%), seguida del Otoño, Invierno y, finalmente, el Verano donde se alcanza un 13.8% de variabilidad explicada.
- El modelo estacional supera al homogéneo en la clasificación correcta de días con precipitación y en la identificación del cambio de estado húmedo a seco. Ninguno de los dos produce una probabilidad ajustada mayor que 0.5 en un día inicial de racha húmeda.
- El modelo con temperatura permite clasificar adecuadamente el 81.1% de

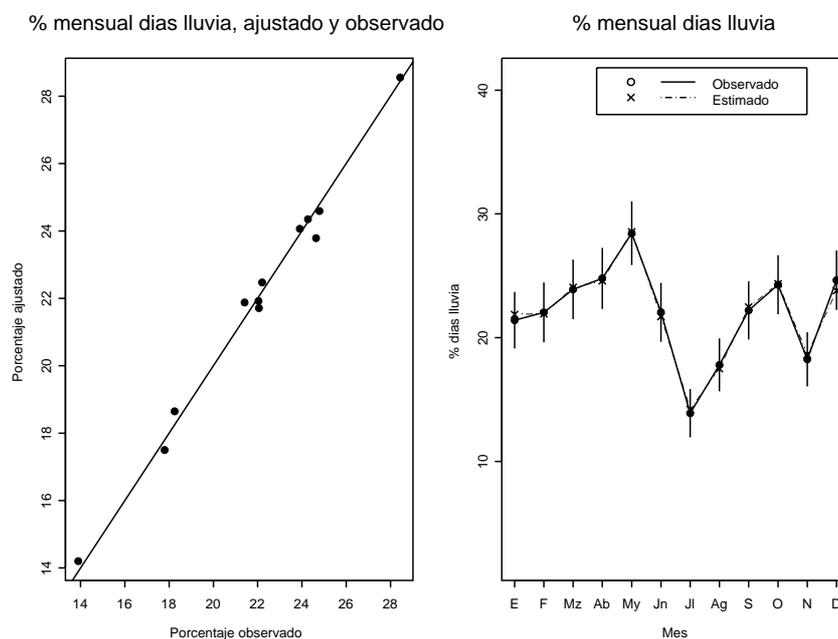


Figura 3.7: Frecuencia mensual de días con precipitación; datos observados y ajustados por *CM temp* en Tortosa (1942-1981).

los días observados, incluyendo un pequeño porcentaje de los días iniciales de racha húmeda.

- El porcentaje de aciertos  $\%NAS$  utilizando el umbral 0.5 es un 0% en *CM hom*, un 8.5% en *CM est* y un 23.4% en *CM temp*, aunque existe una gran diferencia entre el nivel de éxito obtenido en el Verano y en el resto de estaciones.
- Usando la frecuencia relativa como umbral,  $\%NAS$  toma en las estaciones distintas del Verano valores muy parecidos, en torno al 30%, en los 3 modelos.

El comportamiento de los modelos *CM est* y *CM temp* en cuanto a la reconstrucción de las frecuencias mensuales es muy satisfactorio, como se aprecia en la figura 3.7, donde se representan las frecuencias observadas frente a los valores medios de las probabilidades ajustadas por *CM temp* en los 12 meses del año.

En la figura 3.8 aparecen los gráficos de los valores medios de las probabilidades ajustadas en cada año frente a los correspondientes valores observados. Los tres modelos reproducen el orden observado; en los modelos que no utilizan la temperatura, la proporción anual de días con precipitación tiene una

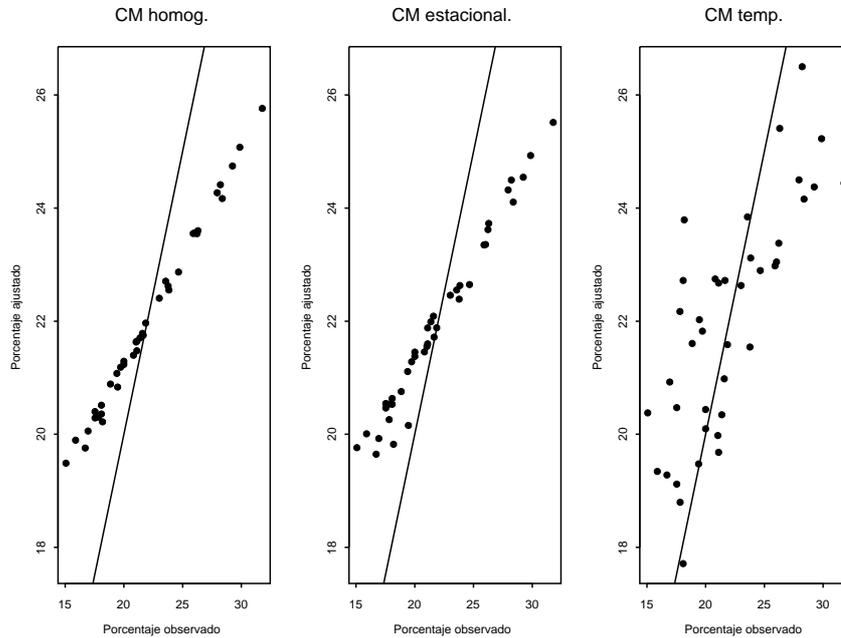


Figura 3.8: Porcentaje de días con lluvia observado anualmente frente al obtenido utilizando los tres modelos de ocurrencia en Tortosa (1942-1981).

relación lineal con las frecuencias observadas que está alejada de la identidad. Por el contrario, el modelo *CM temp* proporciona porcentajes anuales menos alineados que dibujan una nube que recubre mejor la bisectriz, lo que indica una capacidad mayor para reproducir un rango de frecuencias próximo al observado. Los índices de acuerdo y los coeficientes de correlación y eficiencia no permiten distinguir cuál es el mejor modelo en cuanto a la reproducción de la variabilidad de la frecuencia anual.

La evidente relación entre las observaciones sucesivas, que muestra el correlograma en la parte izquierda de la figura 3.9, ha sido capturada por el modelo *CM temp*, como lo indica el correlograma de la serie de residuos en la parte derecha de la figura.

### 3.4.3 Distribución de la longitud de racha

La capacidad de *CM hom* para reproducir la distribución de las longitudes de racha húmeda y seca se puede juzgar comparando la distribución observada con la teórica, que se puede deducir a partir de la matriz de probabilidades de transición. En los otros modelos la distribución se obtiene mediante simulación de la cadena ajustada.

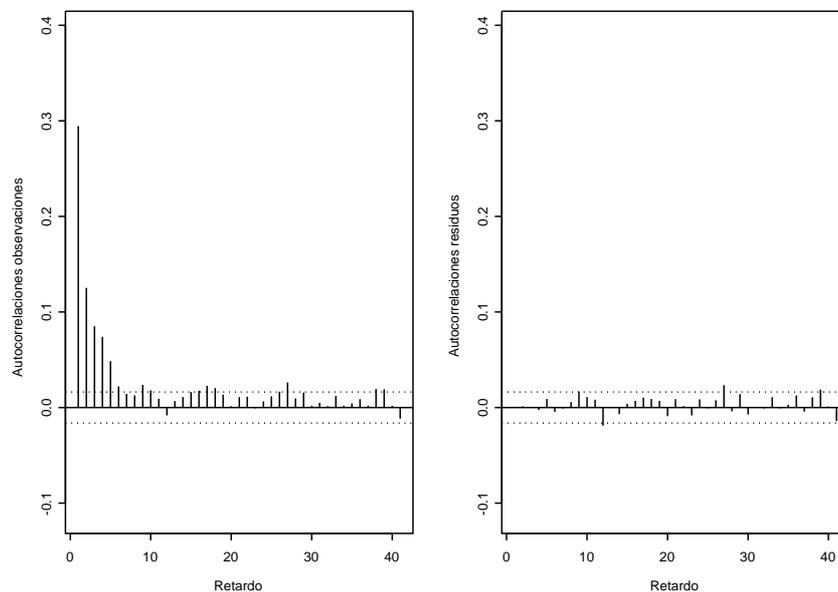


Figura 3.9: Izda.: Correlograma de la serie de ocurrencia observada en Tortosa (1942-1981). Dcha.: Idem de la serie de residuos del modelo *CM temp-T*.

### Cadena de Markov homogénea

Al ser la memoria del proceso de orden 4, la matriz de probabilidades de transición de la cadena binaria es equivalente a la de una cadena de Markov de orden 1 con  $2^4 = 16$  estados que corresponden a la combinación de los estados 0 y 1 en 4 días consecutivos. Desde cada uno de estos estados puede pasarse sólo a dos, ya que debe mantenerse la terna que representa lo ocurrido en los 3 últimos días.

La matriz de probabilidades de transición aparece en la tabla 3.4 y la distribución estacionaria en la tabla 3.5. A partir de ambas se obtiene la distribución de la longitud de las rachas húmedas y secas. Por ejemplo, la probabilidad de que una racha húmeda sea de longitud 1 se obtiene:

$$\begin{aligned}
 P(Y_t = 0 | Y_{t-1} = 1, Y_{t-2} = 0) &= \frac{\sum_{i=0}^1 P(Y_t = 0, Y_{t-1} = 1, Y_{t-2} = 0, Y_{t-3} = i)}{P(Y_{t-1} = 1, Y_{t-2} = 0)} \\
 &= \frac{0.052 + 0.014}{0.052 + 0.014 + 0.043 + 0.012} = 0.545
 \end{aligned}$$

		$(Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3})$															
		0000	1000	0100	1100	0010	1010	0110	1110	0001	1001	0101	1101	0011	1011	0111	1111
0000		0.866	0.134	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1000		0	0	0.56	0.44	0	0	0	0	0	0	0	0	0	0	0	0
0100		0	0	0	0	0.819	0.181	0	0	0	0	0	0	0	0	0	0
1100		0	0	0	0	0	0	0.573	0.427	0	0	0	0	0	0	0	0
0010		0	0	0	0	0	0	0	0	0.83	0.17	0	0	0	0	0	0
1010		0	0	0	0	0	0	0	0	0	0	0.56	0.44	0	0	0	0
0110		0	0	0	0	0	0	0	0	0	0	0	0	0.773	0.227	0	0
1110		0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.573	0.427
0001		0.839	0.161	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1001		0	0	0.506	0.494	0	0	0	0	0	0	0	0	0	0	0	0
0101		0	0	0	0	0.784	0.216	0	0	0	0	0	0	0	0	0	0
1101		0	0	0	0	0	0	0.519	0.481	0	0	0	0	0	0	0	0
0011		0	0	0	0	0	0	0	0	0.797	0.203	0	0	0	0	0	0
1011		0	0	0	0	0	0	0	0	0	0	0.506	0.494	0	0	0	0
0111		0	0	0	0	0	0	0	0	0	0	0	0	0.733	0.267	0	0
1111		0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.519	0.481

Tabla 3.4: Matriz de probabilidades de transición del modelo  $CM\ hom-T$ .

$P(Y_t = 0, Y_{t-1} = 0, Y_{t-2} = 0, Y_{t-3} = 0)$	=	0.487
$P(Y_t = 1, Y_{t-1} = 0, Y_{t-2} = 0, Y_{t-3} = 0)$	=	0.078
$P(Y_t = 0, Y_{t-1} = 1, Y_{t-2} = 0, Y_{t-3} = 0)$	=	0.052
$P(Y_t = 1, Y_{t-1} = 1, Y_{t-2} = 0, Y_{t-3} = 0)$	=	0.043
$P(Y_t = 0, Y_{t-1} = 0, Y_{t-2} = 1, Y_{t-3} = 0)$	=	0.054
$P(Y_t = 1, Y_{t-1} = 0, Y_{t-2} = 1, Y_{t-3} = 0)$	=	0.012
$P(Y_t = 0, Y_{t-1} = 1, Y_{t-2} = 1, Y_{t-3} = 0)$	=	0.031
$P(Y_t = 1, Y_{t-1} = 1, Y_{t-2} = 1, Y_{t-3} = 0)$	=	0.024
$P(Y_t = 0, Y_{t-1} = 0, Y_{t-2} = 0, Y_{t-3} = 1)$	=	0.078
$P(Y_t = 1, Y_{t-1} = 0, Y_{t-2} = 0, Y_{t-3} = 1)$	=	0.018
$P(Y_t = 0, Y_{t-1} = 1, Y_{t-2} = 0, Y_{t-3} = 1)$	=	0.014
$P(Y_t = 1, Y_{t-1} = 1, Y_{t-2} = 0, Y_{t-3} = 1)$	=	0.012
$P(Y_t = 0, Y_{t-1} = 0, Y_{t-2} = 1, Y_{t-3} = 1)$	=	0.040
$P(Y_t = 1, Y_{t-1} = 0, Y_{t-2} = 1, Y_{t-3} = 1)$	=	0.013
$P(Y_t = 0, Y_{t-1} = 1, Y_{t-2} = 1, Y_{t-3} = 1)$	=	0.024
$P(Y_t = 1, Y_{t-1} = 1, Y_{t-2} = 1, Y_{t-3} = 1)$	=	0.020

Tabla 3.5: Probabilidades estacionarias del modelo *CM hom-T*.

Para el cálculo de las probabilidades correspondientes a otras longitudes se utilizan expresiones en las que participan probabilidades de transición y probabilidades marginales; por ejemplo:

$$\begin{aligned}
& P(\text{racha húmeda de longitud 3}) = \\
& = P(Y_t = 0, Y_{t-1} = 1, Y_{t-2} = 1 | Y_{t-3} = 1, Y_{t-4} = 0) \\
& = \frac{P(Y_t = 0, Y_{t-1} = 1, Y_{t-2} = 1, Y_{t-3} = 1, Y_{t-4} = 0)}{P(Y_{t-3} = 1, Y_{t-4} = 0)} \\
& = \frac{P(Y_t = 0 | Y_{t-1} = Y_{t-2} = Y_{t-3} = 1, Y_{t-4} = 0) P(Y_{t-1} = Y_{t-2} = Y_{t-3} = 1, Y_{t-4} = 0)}{P(Y_{t-3} = 1, Y_{t-4} = 0)} \\
& = \frac{0.573 \times 0.024}{0.121} = 0.114
\end{aligned}$$

De esta forma se obtienen las probabilidades asociadas a las distintas longitudes de racha que aparecen en la tabla A.6 junto con las correspondientes frecuencias observadas. Para comparar las distribuciones se realiza un test chi-cuadrado, tomando intervalos cuya frecuencia esperada sea superior a 1 y considerando que el número de parámetros utilizado para encontrar la distribución es el de términos en el predictor lineal ajustado, 7 en este caso. El contraste indica que la distribución ajustada se puede considerar adecuada para las longitudes de las rachas secas pero no para las húmedas.

En la tabla A.7 se muestran los valores de algunos estadísticos y el p-valor de un test chi-cuadrado que compara la distribución observada en cada mes y la propuesta por *CM hom* para los dos tipos de racha. La distribución teórica sólo difiere, al 5%, de la observada para las rachas secas del mes de Julio, donde las observaciones tienen una cola derecha más pesada. En el caso de las rachas húmedas, el test chi-cuadrado es significativo en el mes de Agosto, debido a que las rachas observadas tienen una menor longitud media, y en el de Diciembre por lo contrario.

### Cadena de Markov estacional

Se han realizado 20 simulaciones de la cadena de Markov estacional de una longitud igual al periodo utilizado en la estimación. En las trayectorias simuladas se han analizado las rachas secas y húmedas y estimado la distribución de su longitud. En la tabla A.8 aparecen los resultados de la comparación de éstas con las observadas.

Las rachas secas están bien representadas en todos los meses del año, aunque hay desviaciones superiores a un día en el valor mediano en Enero, Septiembre y Noviembre. El modelo proporciona los mayores percentiles para las rachas secas de Julio, tal como ocurre en la distribución observada. Lo que muestra su capacidad para captar la mayor persistencia del estado seco durante el Verano.

Para las rachas húmedas, los percentiles calculados son semejantes en todos los meses del año; la mayor diferencia observada es de 0.7 días y corresponde al percentil 90 en el mes de Agosto y al valor de la mediana en Mayo.

### Cadena de Markov con información de temperatura

Se han simulado 20 trayectorias de *CM temp* utilizando los valores observados de las covariables en el periodo de estimación. El grado de semejanza entre las características de la trayectoria observada y las simuladas es satisfactorio, como muestra la figura 3.10, en la que se comparan el correlograma de la serie observada y la media de las autocorrelaciones calculadas en las 20 simulaciones.

Las simulaciones permiten obtener las distribuciones, por meses, de la longitud de las rachas secas y húmedas, que se comparan con las observadas. En la tabla A.9 aparecen los resultados de esta comparación.

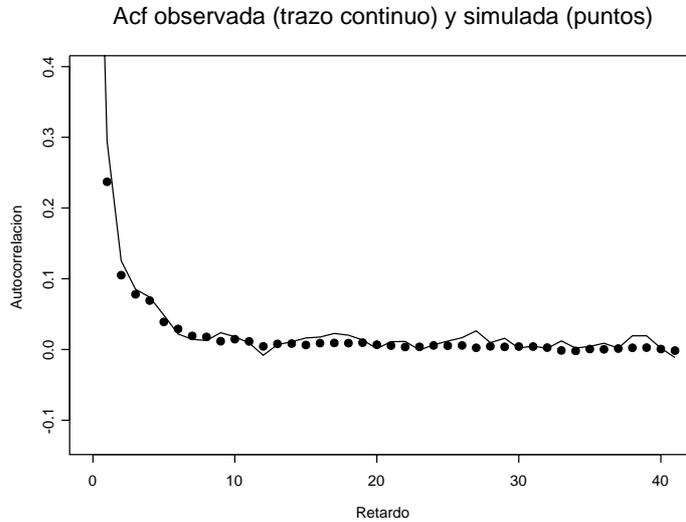


Figura 3.10: Correlograma de la serie de ocurrencia observada en Tortosa (1942-1981) y valores medios de las autocorrelaciones obtenidas en 20 simulaciones de *CM temp*.

La distribución de la longitud de las rachas secas simuladas no se distingue significativamente de la muestral, salvo en el mes de Septiembre. En ese mes la mediana y el percentil 90 de la distribución simulada han disminuido en 1.5 días y la dispersión es menor. El modelo propone rachas de longitud máxima en el mes de Julio, como ocurre en los datos observados.

En cuanto a las rachas húmedas, las trayectorias simuladas muestran discrepancias significativas con la distribución observada en los meses de Marzo y Diciembre; en ellos el valor mediano de las rachas generadas es un día menor que el observado. En las figuras 3.11 y 3.12 aparecen gráficos con los percentiles observados y simulados en Diciembre y Junio, mes en el que *CM temp* reproduce aceptablemente la distribución de la longitud de las rachas húmedas.

Se concluye que tanto el modelo estacional como el que usa covariables de temperatura reproducen adecuadamente las longitudes de rachas secas. En el caso de las rachas húmedas el modelo *CM temp* se comporta peor que *CM est*.

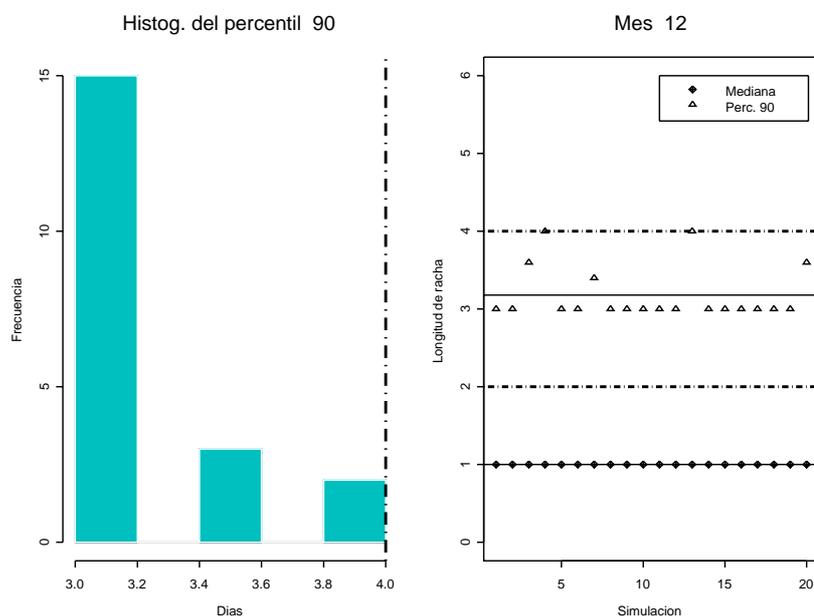


Figura 3.11: Percentiles de la distribución de la longitud de las rachas húmedas: datos observados y simulados a partir de  $CM\ temp-T$ , en Diciembre. La línea discontinua indica el valor observado del percentil, los símbolos indican el correspondiente valor obtenido en cada simulación y la línea continua representa su valor medio.

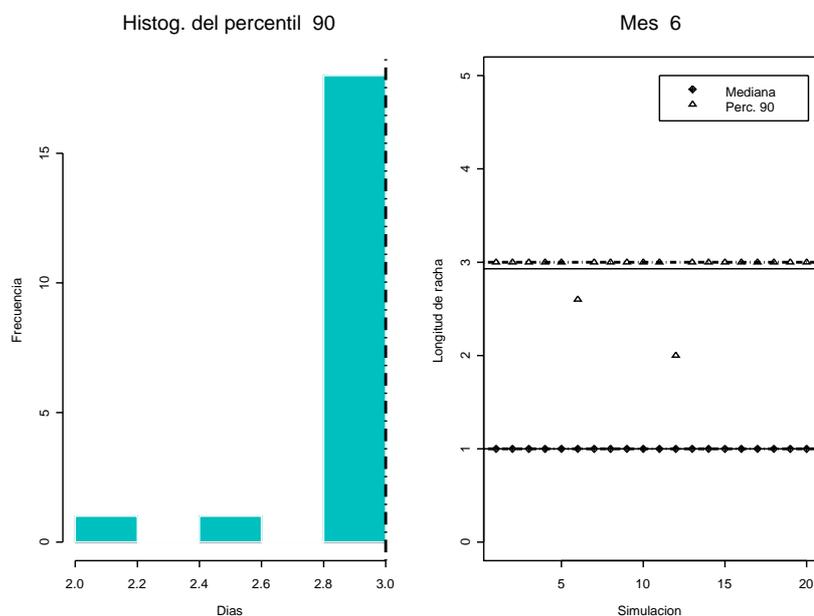


Figura 3.12: Percentiles de la distribución de la longitud de las rachas húmedas: datos observados y simulados a partir de  $CM\ temp-T$ , en Junio.

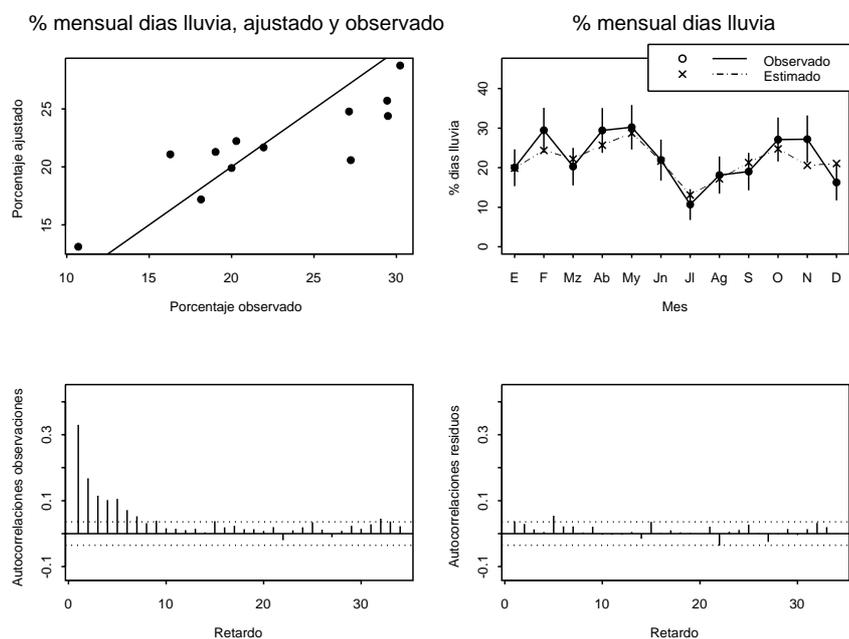


Figura 3.13: Comportamiento de  $CM\ est-T$  en el periodo de validación (1982-1991).

### 3.4.4 Comportamiento en el periodo de validación

Las tablas A.10, A.11 y A.12 muestran las medidas de la bondad de ajuste cuando los modelos se aplican a los datos reservados para validación. Respecto del periodo de estimación, los tres modelos presentan un incremento del porcentaje de variabilidad explicada que, según indica el coeficiente relativo de Brier, se debe a la mejor representación de la ocurrencia en Otoño.

El tanto por ciento de días bien clasificados es semejante al valor obtenido en el periodo de ajuste en los tres modelos. Hay un incremento relevante, alrededor de un 10%, en Otoño para el porcentaje  $\%NAS$ , cuando se utiliza la frecuencia diaria de lluvia como umbral.

Las medias mensuales de las probabilidades ajustadas por los modelos  $CM\ est$  y  $CM\ temp$  subestiman los valores observados en algunos de los meses con mayor frecuencia relativa, Febrero, Abril y Noviembre, aunque quedan dentro del intervalo de semiamplitud 2 desviaciones estándar, centrado en la frecuencia media mensual, ver figuras 3.13 y 3.14. Esto se debe a la rigidez de los modelos, que siguen reproduciendo el ciclo estacional observado en el periodo de estimación, ver figura 3.7, donde las frecuencias de los meses citados eran sensiblemente menores a los valores máximos de Mayo y Octubre.

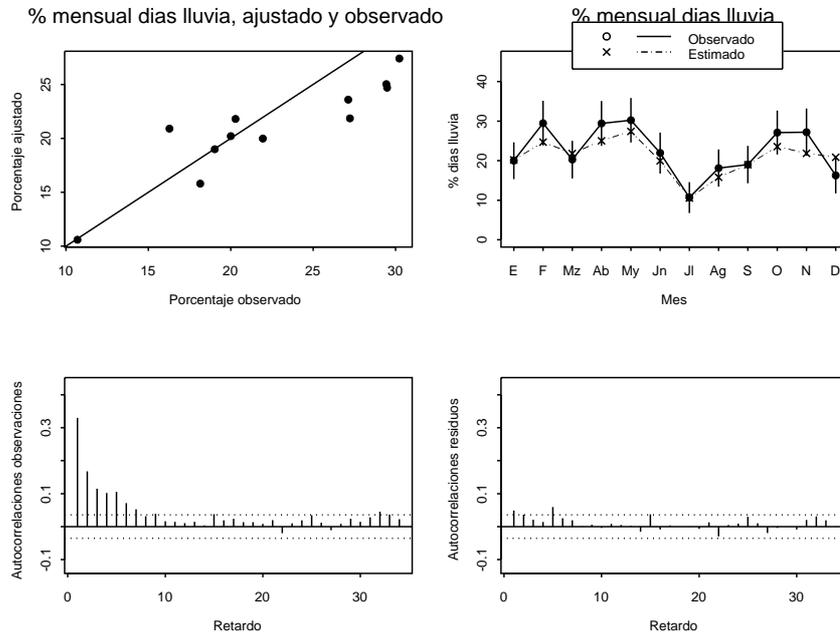


Figura 3.14: Comportamiento de  $CM\ temp-T$  en el periodo de validación (1982-1991).

Aunque los modelos recogen la mayor parte de la dependencia existente en las observaciones, la estructura de autocorrelación de los residuos no corresponde a la de un ruido blanco. La autocorrelación de los residuos de  $CM\ temp$  en los primeros retardos, podría indicar la necesidad de un orden de memoria superior para modelar el periodo de validación.

### Distribución de la longitud de racha

La longitud del intervalo temporal utilizado en la validación es la cuarta parte del usado en la estimación, por lo que el número de rachas observadas es sensiblemente menor. Esto explica la ausencia de significación estadística pese a las mayores discrepancias entre los estadísticos observados y ajustados con  $CM\ hom$ , ver tabla A.13. Salvo para las rachas húmedas de Noviembre no se rechaza la igualdad de distribuciones.

Las tablas A.14 y A.15 comparan algunas características de las longitudes de racha observadas en este periodo con las generadas simulando  $CM\ est$  y  $CM\ temp$ , respectivamente. Como en el modelo homogéneo, la distribución observada de las longitudes de racha húmeda en Noviembre es significativamente distinta a la obtenida en las simulaciones. En este mes, la mediana y

el intervalo intercuartílico de la longitud de las rachas húmedas observadas se incrementan con respecto a sus valores en el periodo de estimación, mientras que en la longitud de racha seca se produce el hecho contrario. El incremento de la persistencia del estado húmedo, reflejado también en la frecuencia relativa de lluvia, no es señalado por ninguno de los modelos.

Se puede establecer, como conclusión, que las dificultades de los modelos para reproducir la distribución de la longitud de racha húmeda están en los meses de Marzo y Diciembre en el periodo de ajuste y en el de Noviembre en el de validación. En estos meses la mediana observada es igual a 2 días y los modelos, incapaces de generar esa persistencia, producen rachas de mediana inferior a 1.6 días.

### 3.5 Modelos para la ocurrencia de precipitación en el observatorio de Reinosa

Reinosa se encuentra situada en la cabecera del río Ebro, en las proximidades de la Cordillera Cantábrica. Se trata de un observatorio termopluviométrico, atendido por un colaborador, que estuvo bajo la competencia del centro del INM en Zaragoza hasta la reorganización de los centros territoriales. En la actualidad depende del centro de Santander.

En Reinosa existen 3 periodos de observaciones: el primero comienza en 1912 y acaba en 1975, el segundo se reduce a los años 1977 y 1978 y el tercero comprende desde 1985 hasta 1994; en la actualidad este observatorio no está activo. En cada uno de estos periodos las medidas fueron realizadas por observadores distintos, produciéndose cambios de emplazamiento de la estación. Por ello, existen dudas sobre la homogeneidad de los registros en los distintos periodos y se decidió realizar los ajustes con los datos de la primera época. Se han tomado los datos de 1912 a 1959 para realizar la estimación y se han reservado los años entre 1960 y 1975 para la validación.

En la subsección 3.5.1 se presentan los modelos ajustados y se señalan las características de más interés de sus predictores lineales. En la subsección 3.5.2 se evalúa el comportamiento global de los modelos y en la 3.5.3 su capacidad para representar la longitud de las rachas. En la subsección 3.5.4 se hace un análisis de su comportamiento sobre el conjunto de datos de validación. Finalmente, en la 3.5.5 se utilizan los modelos ajustados para estudiar la existencia de algún tipo de inhomogeneidad en las medidas de precipitación del periodo 1985-1994, con respecto a las de 1912-1975.

#### 3.5.1 Modelos ajustados

En las tablas A.16 y A.17 se presentan los tres modelos ajustados en Reinosa. Cabe destacar que el modelo homogéneo necesita un orden de memoria 6, mayor que el requerido en Tortosa con una longitud de registro equivalente; en los otros dos modelos este orden se reduce a 3.

En el modelo *CM hom*, el efecto positivo ligado a la presencia de lluvia en los retardos iguales o superiores a 4 días, tiene un valor semejante que es, aproximadamente, la mitad del efecto de  $Y_{t-3}$ . Los efectos correspondientes a los días  $t - 1$  y  $t - 2$  no son aditivos, existe un término de interacción de signo negativo que anula el efecto de  $Y_{t-2}$ .

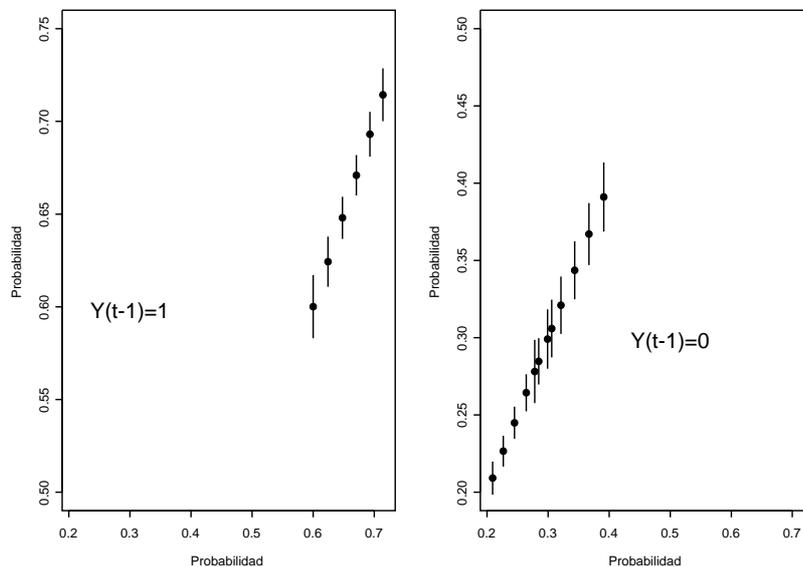


Figura 3.15: Probabilidades de ocurrencia ajustadas con  $CM\ hom^*$  en Reinosa (1912-1959). Se indican los intervalos de confianza al 95%.

A partir de las relaciones que se observan en los coeficientes cabe reformular este modelo para simplificar su expresión. En la siguiente tabla aparecen los términos del modelo reparametrizado, referenciado como  $CM\ hom^*$ , que produce prácticamente el mismo ajuste: su desviación es 20848.37 frente a 20844.96 de  $CM\ hom$ .

Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-1.142	0.0340	-33.580
$\bar{Y}_{t-1}$	1.736	0.0380	45.700
$(1 - Y_{t-1}) \times Y_{t-2}$	0.1882	0.0258	7.292
$2 \times Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6}$	0.1022	0.0102	10.020

En cada una de las 18 situaciones de memoria que se diferencian en  $CM\ hom^*$ , la probabilidad de ocurrencia sólo supera el valor 0.5 si llueve en el día previo, ver figura 3.15; los efectos restantes tienen mucho menor impacto.

Los efectos asociados a la memoria del proceso en el modelo estacional toman valores semejantes a los correspondientes del modelo homogéneo, ver tabla A.16. En la figura 3.16 se aprecia que las mayores probabilidades ajustadas por este modelo se producen en las situaciones con lluvia en el día previo, siendo menores que 0.5 sólo en el Verano. En esa figura se observa también el efecto de la interacción entre los armónicos y los dos primeros

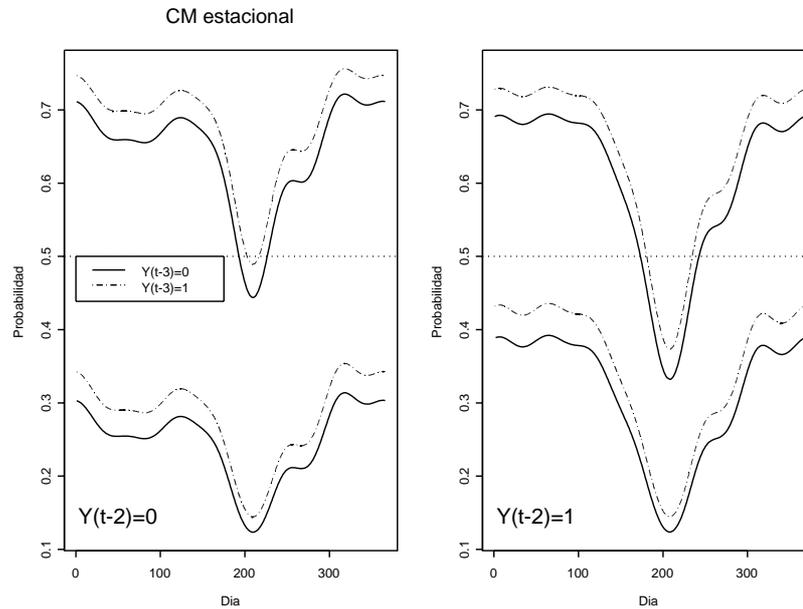


Figura 3.16: Probabilidades de ocurrencia ajustadas en Reinosa con el modelo *CM est.* Las dos curvas que aparecen en la parte superior de cada gráfica corresponden a la situación  $Y_{t-1} = 1$ .

retardos de la ocurrencia.

En el predictor de *CM temp*, ver tabla A.17, los coeficientes relativos a la memoria del proceso son comparables a los de los dos modelos anteriores. La incorporación de nuevas covariables no simplifica demasiado la estructura de dependencia y armónicos del modelo estacional.

El efecto de la variable  $TDIF_t$ , el más significativo, cambia dependiendo de lo que ocurre en los dos días previos y requiere, en algunas situaciones, un término cuadrático. En la figura 3.17 se observa que, cuanto mayor es el rango de temperatura menor es la probabilidad de ocurrencia y que existe una gradación en el efecto del rango dependiendo de la ocurrencia en los dos días previos. El rango del día  $t - 1$ , por el contrario, tiene un efecto positivo aunque de menor valor absoluto que el del día  $t$ .

La temperatura mínima tiene un efecto no lineal que se muestra en la figura 3.18. El efecto es decreciente cuando llueve en el día  $t - 2$ ; en caso contrario, la probabilidad de lluvia se incrementa cuando  $TMIN_t$  toma valores extremos.

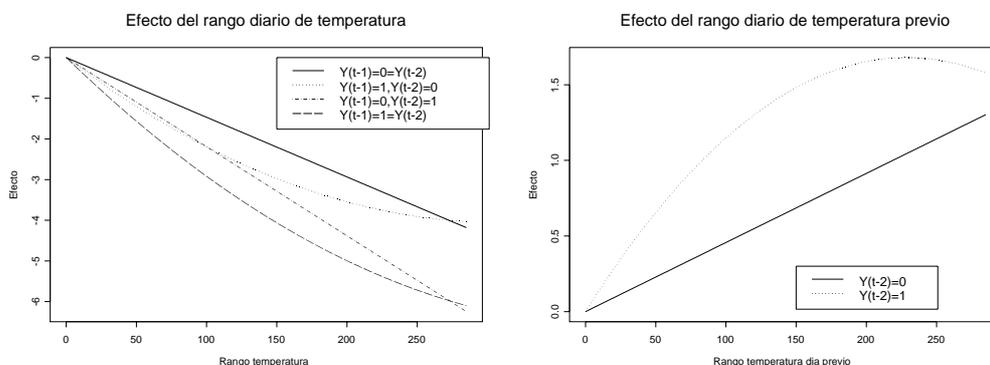


Figura 3.17: Ajuste de *CM temp* en Reinosa. Izda.: Efecto del rango de temperatura en el día  $t$ . Dcha.: Efecto del rango en el día  $t - 1$ .

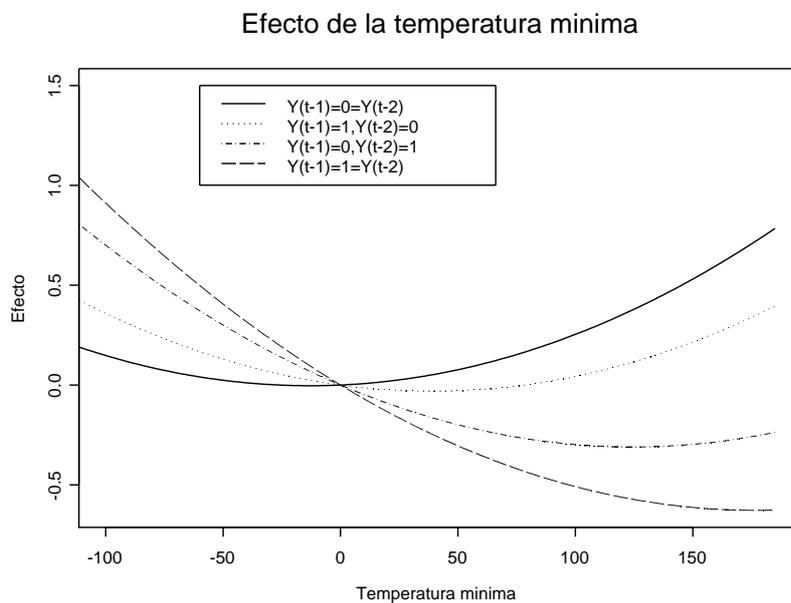


Figura 3.18: Ajuste de *CM temp* en Reinosa. Efecto de la temperatura mínima.

### 3.5.2 Crítica de los modelos ajustados

En las tablas A.18, A.19 y A.20 aparecen las medidas de bondad de ajuste de los modelos ajustados. A continuación se destacan los aspectos más relevantes:

- En general, las medidas de las cadenas homogénea y estacional son semejantes, aunque esta última consigue clasificar correctamente algunos de los días de cambio de estado. Las diferencias entre estos dos modelos se producen esencialmente en el Verano, donde:
  - el índice relativo de Brier de *CM est* duplica al de *CM hom*,
  - utilizando la frecuencia relativa como umbral, la proporción de días bien clasificados es un 33.7% en *CM hom* y un 68.5% en *CM est*,
  - *CM est*, a diferencia de *CM hom*, consigue reproducir la frecuencia de lluvia en los meses de Julio y Agosto.
- El modelo *CM temp* representa una mejora considerable: el porcentaje de variabilidad explicada aumenta en todas las estaciones, en menor grado en el Verano, y es el único modelo que clasifica correctamente algunos días iniciales de racha húmeda, aunque el porcentaje de éxito sea bajo.
- Los tres modelos reproducen correctamente la estructura de dependencia de las observaciones.
- Para los tres, el porcentaje %NAS es cercano al 50% en Primavera, Otoño e Invierno. En Verano, cuando abundan los días secos, este porcentaje desciende a un 34% en *CM hom*, a un 27% en *CM est* y a un 28% en *CM temp*.
- Dada la proximidad de la frecuencia relativa diaria de lluvia con el valor 0.5, salvo en Verano, el porcentaje de aciertos con las dos clasificaciones es semejante.

Los índices basados en la frecuencia relativa anual de lluvia no diferencian entre los tres modelos, a pesar de que *CM temp* reproduce mejor la variabilidad interanual. En la figura 3.19 se aprecia cómo la nube de los puntos definidos por los porcentajes observados y estimados queda más próxima de la recta  $y = x$  para este último modelo.

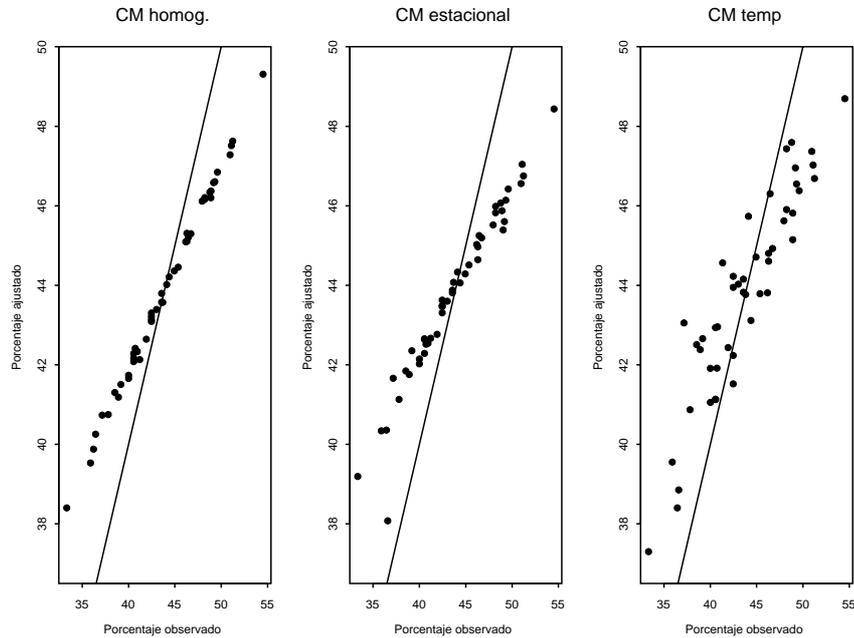


Figura 3.19: Porcentaje observado de días con lluvia en cada año frente al obtenido en el ajuste con los modelos de ocurrencia en Reinosa (1912-1959).

### 3.5.3 Distribución de la longitud de racha

#### Cadena de Markov homogénea

Con el modelo homogéneo se obtienen las distribuciones de longitud de racha que se indican en la tabla A.21. El test chi-cuadrado, aplicado sin diferenciar estaciones, no rechaza la igualdad de distribuciones en ninguno de los dos tipos de racha. Al hacer una valoración en periodos de tiempo más homogéneos, por meses, ver tabla A.22, se encuentran algunas discrepancias. La igualdad de distribución se rechaza para las rachas secas en los meses de Julio y Agosto. La longitud de racha húmeda tiene una distribución que no es significativamente distinta de la observada en Septiembre y en los meses entre Febrero y Mayo, en el resto del año no puede asumirse que la distribución teórica represente adecuadamente lo observado.

#### Cadena de Markov estacional

Se han simulado 20 series de ocurrencia diaria de una longitud igual a la del periodo de estimación. En la tabla A.23 aparecen los percentiles 50 y 90 de las distribuciones de la longitud de racha en cada mes, junto con los correspondientes valores observados y el p-valor de un test KS para valorar

la igualdad de ambas distribuciones.

Para las rachas secas no se rechaza la igualdad en ningún mes; la mediana está bien reproducida y únicamente se encuentran discrepancias mayores de un día en el rango intercuartílico del mes de Febrero y en el percentil 90 de los meses de Marzo y Julio.

En el caso de las rachas húmedas las distribuciones propuestas por el modelo son adecuadas en todos los meses salvo en el de Agosto, donde se rechaza al 5%. En este mes, el modelo produce rachas más largas que las observadas.

### Cadena de Markov con información de temperatura

Los resultados para el modelo con temperatura se muestran en la tabla A.24 y ponen de manifiesto las discrepancias entre los percentiles de las distribuciones observada y simulada de las rachas secas en los meses de Junio y Agosto. Para las rachas húmedas, el test de Kolmogorov-Smirnov rechaza al 5% la igualdad de distribución para todos los meses entre Abril y Octubre, excepto Agosto.

Se puede afirmar que el modelo *CM temp* tiende a generar rachas, de los dos tipos, más breves que las observadas, con la excepción de las rachas húmedas en Diciembre y las secas en Junio y Diciembre. La menor dispersión de las distribuciones que ajusta *CM temp*, respecto de las observadas, hace que, pese a ajustar mejor otras facetas de los datos, el modelo represente la longitud de las rachas peor que los modelos más simples.

### 3.5.4 Comportamiento en el periodo de validación

El grado de ajuste que proporcionan los modelos en el periodo de validación, 1960-1975, se muestra en las tablas A.25, A.26 y A.27. Se puede afirmar que los modelos han captado las características estables de la lluvia puesto que alcanzan el mismo grado de ajuste que en el periodo de estimación. El porcentaje global de variabilidad explicada se incrementa ligeramente, mientras se producen leves oscilaciones en las distintas estaciones. *CM temp* mantiene su capacidad para caracterizar las situaciones de cambio de racha en un porcentaje relevante de días y los porcentajes de clasificación correcta en los días de cambio de estado son similares a los obtenidos en el conjunto de estimación.

El comportamiento de los modelos en los meses de Verano del periodo de

validación es peor. El modelo *CM temp* proporciona un índice relativo de Brier del mismo orden, un 10%, que el obtenido con el modelo estacional en el periodo de estimación; Junio es el mes peor representado por *CM est*, que estima un 35.2% de días con precipitación cuando se observa un 29.9%. Este desajuste se mantiene en el modelo con temperaturas.

### Distribución de la longitud de racha

Las tablas A.28, A.29 y A.30 permiten comparar la distribución observada de las longitudes de racha en el periodo 1960-1975 con las que proporcionan los modelos ajustados.

Las longitudes de las rachas secas observadas en los meses del Verano tienen distribuciones significativamente distintas de las propuestas por el modelo homogéneo, análogamente a lo que ocurría en el conjunto de estimación. Para las rachas húmedas sólo se rechaza la igualdad de distribuciones en Julio; en otros meses, como Noviembre y Diciembre, debido al menor tamaño de muestra, no existe evidencia suficiente para el rechazo a pesar de las diferencias existentes entre los estadísticos.

El modelo estacional genera rachas de longitud análoga a la de las observadas, tal como ocurre en el periodo de estimación. Las discrepancias más notables se producen en el rango intercuartílico de Junio y en la mediana de la longitud de racha húmeda de Julio.

Con el modelo *CM temp* aparecen diferencias relevantes, que pueden ser significativas o no, en las rachas secas de algunos meses en los que ya se advertía discrepancia en el periodo de estimación (mediana de Agosto, rango intercuartílico de Julio, Septiembre y Octubre). Para las rachas húmedas, el modelo proporciona en el periodo de validación percentiles más acordes con los observados, excepto en los meses de Agosto y Septiembre.

### 3.5.5 Análisis de homogeneidad en el periodo 1985-1994

La toma de observaciones en Reinososa sufrió una interrupción en 1975 y volvió a reanudarse de forma continuada en 1985. Hemos considerado de interés analizar el comportamiento de los modelos en el periodo 1985-1994, con el fin de analizar la posible inhomogeneidad de esas observaciones respecto de la serie medida hasta 1975.

El estudio se centra en detectar algún tipo de cambio en la frecuencia de

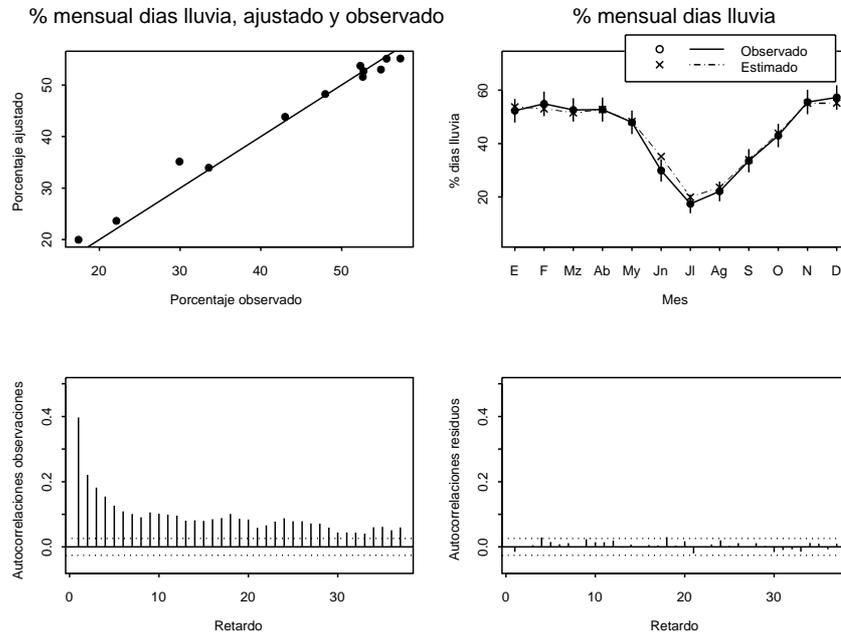


Figura 3.20: Comportamiento de *CM est* en Reinosa en el periodo de validación (1960-1975).

ocurrencia para lo que, en primer lugar, se comparan las medidas de bondad de ajuste de los tres modelos en el conjunto de validación y en este último periodo de registro. Si el comportamiento de las observaciones fuera homogéneo, el resultado de su evaluación en ambos periodos debería coincidir.

Las tablas A.31, A.32 y A.33 contienen las medidas de bondad de ajuste correspondientes al periodo 1985-1994. El modelo homogéneo muestra un comportamiento discrepante del que tiene en el periodo 1960-1975, en Otoño, donde se produce una disminución del índice relativo de Brier de un 19.4% a un 13.5%, y en Verano, donde se observa una disminución del porcentaje de días bien clasificados. Estos cambios ocurren también en los modelos *CM est* y *CM temp*.

Las figuras 3.20 y 3.21 permiten evaluar el grado de ajuste del modelo *CM est* en el periodo de validación y en 1985-1994, respectivamente. En este último periodo el modelo proporciona el mayor valor medio ajustado en Abril, mes en el que se observa la mayor frecuencia; sin embargo, ambos valores distan más de 2 errores estándar de la media observada, lo que ocurre también en el mes de Julio. Esta situación no se produce en ningún mes en el periodo de validación.

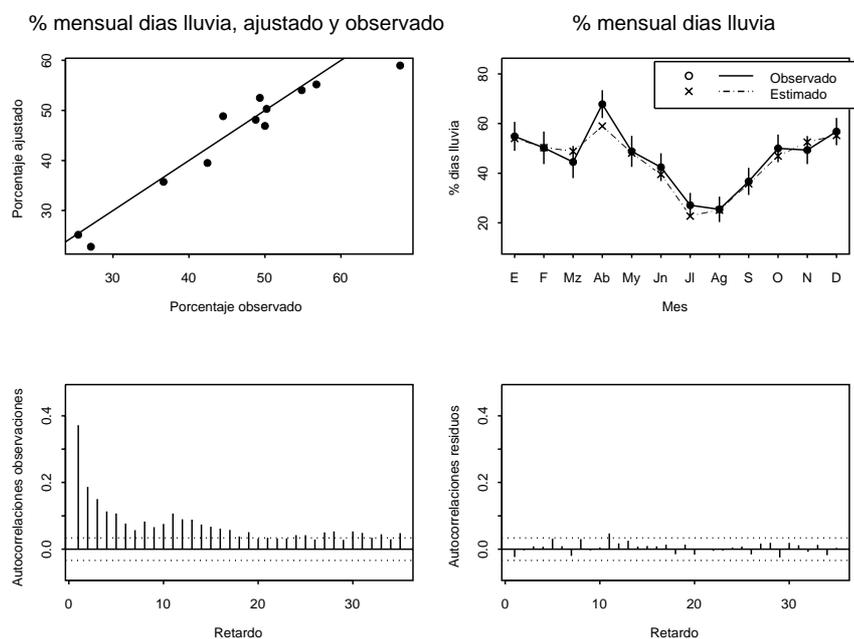


Figura 3.21: Comportamiento de  $CM\ est$  en Reinosa (1985-1994).

Utilizando una aproximación alternativa, se decidió incluir términos adicionales en los modelos para analizar si existía un comportamiento distinto al caracterizado por los datos de 1912 a 1959. Para ello se ajustó a los datos del periodo 1985-1994 un modelo de regresión logística con un 'offset' igual al predictor lineal de  $CM\ est$  estimado en el periodo 1912-1959 y se comprobó si requería algún parámetro adicional. Para valorar si se producían cambios en alguna época del año, se estudió el efecto de un factor que identificaba la estación del año. Este análisis estuvo motivado por la experiencia en homogeneización de series de precipitación estacional en la cuenca del Ebro, donde se han detectado, en ocasiones, inhomogeneidades que sólo afectan significativamente a alguna estación.

En la tabla 3.6 se muestra un ajuste que incluye la interacción entre el indicador de lluvia en el día previo y el factor que define las estaciones. Notemos que el régimen de ocurrencia de precipitación del periodo 1985-1994 cambia significativamente en el Verano, estación en la que se incrementa la frecuencia de lluvia y disminuye el efecto asociado a la ocurrencia en el día previo. Estos hechos no se evidenciaban en el periodo 1960-1975.

Si se realiza el mismo ejercicio con el modelo  $CM\ temp$ , se obtiene un predictor lineal que requiere, además del efecto del 'offset', términos para las

Término	1985-1994			1960-1975		
	Coef.	Err. std.	Est. $t$	Coef.	Err. std.	Est. $t$
<i>Primavera</i>	0.0838	0.1163	0.720	0.1012	0.0794	1.274
<i>Verano</i>	0.2983	0.09751	3.060	-0.1523	0.08207	-1.855
<i>Otoño</i>	0.03568	0.1001	0.357	-0.1024	0.08264	-1.239
<i>Invierno</i>	0.03155	0.1102	0.286	0.06097	0.08451	0.722
$Y_{t-1}:Primavera$	-0.02184	0.1602	-0.136	-0.2191	0.1112	-1.971
$Y_{t-1}:Verano$	-0.3817	0.1557	-2.452	-0.09789	0.1387	-0.706
$Y_{t-1}:Otoño$	-0.02645	0.1446	-0.183	0.205	0.1204	1.703
$Y_{t-1}:Invierno$	0.02033	0.1532	0.133	-0.04109	0.1163	-0.353

Tabla 3.6: Modelo estacional de ocurrencia ajustado en Reinosa en los periodos 1985-1994 y 1960-1975, que utiliza como ‘offset’ el predictor lineal de *CM est-R* estimado en 1912-1959.

Término	Coefficiente	Error std.	Estadístico $t$
$S1$	0.1860	0.06849	2.716
$C1$	0.1336	0.0820	1.634
$S2$	-0.03697	0.05773	-0.640
$C2$	0.03877	0.05661	0.685
$S3$	-0.03132	0.05725	-0.547
$C3$	0.04638	0.05702	0.813
$S4$	0.1186	0.05686	2.086
$C4$	0.1225	0.05729	2.139
$S5$	0.006286	0.05717	0.110
$C5$	0.03290	0.05692	0.578
$S6$	-0.1210	0.0571	-2.119
$C6$	-0.06428	0.05679	-1.132
$TDIF_{t-1}$	-0.001804	5.374e-4	-3.358
$TMIN_t$	0.00463	0.001215	3.811

Tabla 3.7: Modelo de ocurrencia con temperaturas ajustado en Reinosa en 1985-1994 que utiliza como ‘offset’ el predictor lineal de *CM temp-R* estimado en el periodo 1912-1959.

covariables  $TMIN_t$  y  $TDIF_{t-1}$ , así como para algunos armónicos, ver tabla 3.7. El modelo tiene asociada una reducción de 35.6 en la deviance, respecto al modelo que utiliza sólo el ‘offset’, reducción que es significativa al 0.001. Esto representa un cambio en la relación de la temperatura con la ocurrencia de precipitación, respecto a la modelada en el periodo 1912-1959; por una parte se incrementa el efecto positivo de la temperatura mínima, por otra se reduce en casi un 40% el coeficiente del efecto lineal del rango en el día previo.

A la vista de estas modificaciones se concluye que el comportamiento de la ocurrencia en el registro de 1912-1959 no se corresponde con el del intervalo 1985-1994, ni en lo referente a la frecuencia de lluvia ni en cuanto a la relación con las covariables de temperatura. Esta falta de homogeneidad, detectada mediante un procedimiento absoluto, utilizando únicamente los datos de la propia serie, debería analizarse con métodos relativos que tuvieran en cuenta lo ocurrido en los observatorios próximos, para decidir si los cambios detectados están asociados a una evolución climática en ese territorio o son consecuencia de una perturbación atribuible a los cambios de emplazamiento y observador.

### 3.6 Modelos para la ocurrencia de precipitación en el observatorio de Agoncillo

En el aeródromo de Agoncillo, próximo a Logroño, se halla situado un observatorio principal del INM. De él se han utilizado los registros diarios de cantidad de precipitación, temperaturas máxima y mínima y las medidas en las horas tipo de la presión atmosférica.

La presión atmosférica se mide a las 0, 7, 13 y 18 horas de cada día y se expresa en décimas de hectoPascal. La notación utilizada indica la hora a la que corresponde la observación: se denota  $P_{h_t}$  a la medida de presión hecha a las  $h$  horas del día  $t$ . Dada la relación existente entre la precipitación y la presión atmosférica, tiene interés considerar variables derivadas que reflejen la evolución temporal de esta magnitud; así, por ejemplo, la variable  $\Delta P_{18.13_t}$  es la diferencia entre la presión a las 18 horas del día  $t$  y la registrada a las 13 horas del mismo día.

En la figura 3.22 se aprecia que el valor medio de las 4 medidas de presión en un día no coincide. La mayor o menor insolación distingue, sobre todo, las medidas correspondientes a las horas de luz solar (13 y 18 horas) de las nocturnas. Un valor de  $P_{00_t}$  puede corresponder a una situación de baja presión respecto de su nivel medio diario y esa misma presión representar a las 18 horas una presión alta en relación a su media. Además, el diferente perfil de evolución de las medidas horarias, implica que los cambios de presión entre horas consecutivas tengan distinto valor medio y diferente evolución a lo largo del año, ver figura 3.23.

A consecuencia de este hecho hemos definido anomalías diarias de las covariables relativas a la presión, como la diferencia entre el valor de la covariable en el día  $t$  y su valor medio en ese día del año; valor medio que se obtiene mediante una regresión de la covariable con los 4 primeros armónicos de un desarrollo de Fourier. Se denota  $z.P_{18_t}$ , por ejemplo, a la anomalía correspondiente a la presión a las 18 horas del día  $t$ .

Como en las secciones dedicadas a Tortosa y Reinos, en la subsección 3.6.1 se destacan los aspectos más relevantes de los modelos ajustados. La subsección 3.6.2 se dedica a la crítica de los modelos y la 3.6.3 al análisis de su capacidad para reproducir las longitudes de racha. Por último, en la 3.6.4 se presentan los resultados obtenidos en el periodo de validación.

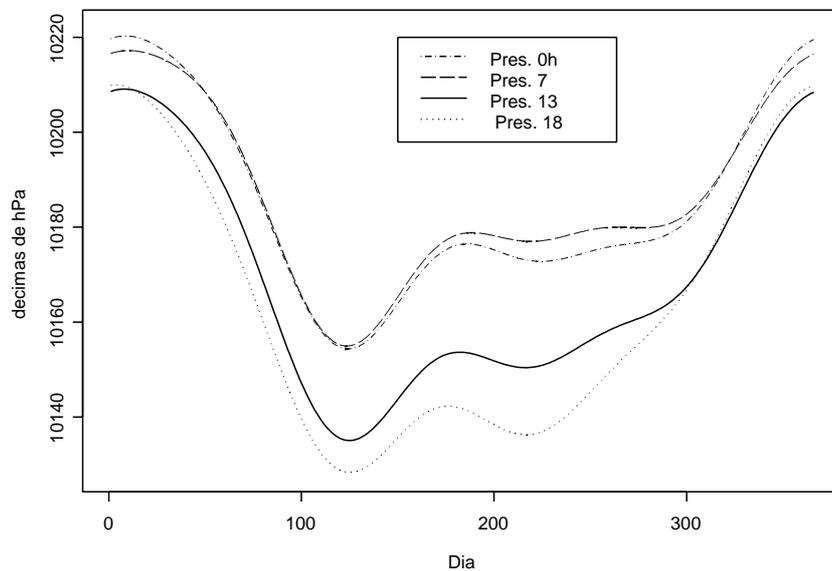


Figura 3.22: Suavizado del valor medio diario de la presión en las horas tipo, Agoncillo (1978-1997).

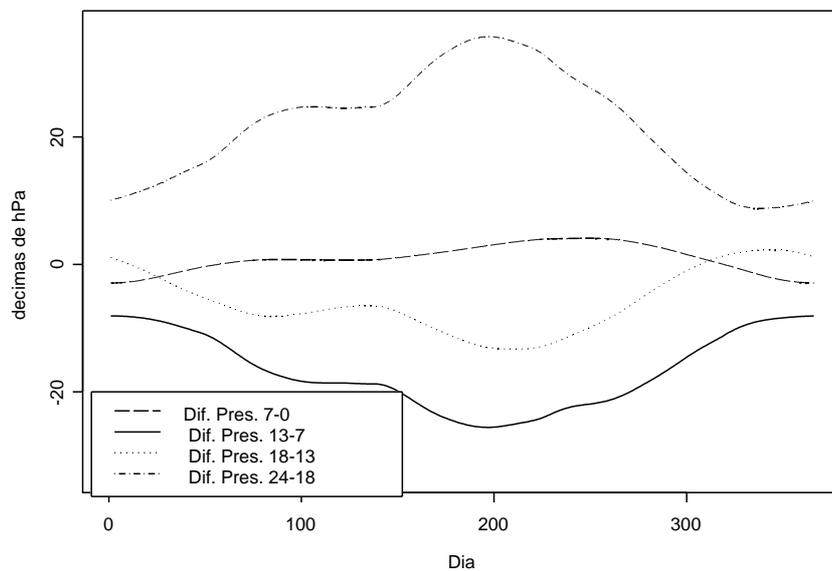


Figura 3.23: Evolución de la diferencia de presión entre medidas consecutivas, Agoncillo (1978-1997).

### 3.6.1 Modelos ajustados

Los modelos ajustados en Agoncillo se estiman con los datos del periodo 1978-1992 y su validación se realiza con los comprendidos entre 1993 y 1997.

Las tablas A.34 y A.35 muestran los predictores lineales correspondientes a los cinco modelos markovianos ajustados:

- una cadena de Markov homogénea, *CM hom*, un modelo estacional, *CM est*, y un modelo que incluye, además de los armónicos, las temperaturas máxima y mínima diarias, *CM temp*,
- un modelo *CM pres* que incorpora al modelo estacional las covariables relativas a la presión atmosférica,
- finalmente, un modelo *CM tempres* que incluye todas las covariables anteriores.

El análisis de los predictores resultantes permite destacar los siguientes resultados:

- Como en los observatorios estudiados, la ocurrencia de precipitación en el pasado inmediato aumenta la probabilidad de ocurrencia de lluvia. De nuevo, el efecto de los sucesivos retardos no es aditivo ya que existe un efecto negativo de interacción entre los indicadores  $Y_{t-1}$  e  $Y_{t-2}$ .
- La memoria del proceso disminuye según se introduce información en el predictor lineal. Frente a un orden 4 que requiere el modelo homogéneo, el modelo estacional es de orden 3 y *CM temp* o *CM pres* son de orden 2. Esto indica que la memoria del propio proceso sustituye en los modelos simples a la información que proporcionan otras covariables climáticas influyentes.
- El rango de temperatura en el día  $t$  tiene asociado el mayor valor del estadístico  $t$  en todos los modelos en los que aparece.
- Como en Tortosa y Reinosa, el rango de temperatura en el día  $t - 1$  tiene un efecto significativo, de signo contrario al del día  $t$ .
- En cuanto al efecto de las covariables de temperatura en el predictor lineal de *CM tempres* cabe reseñar:

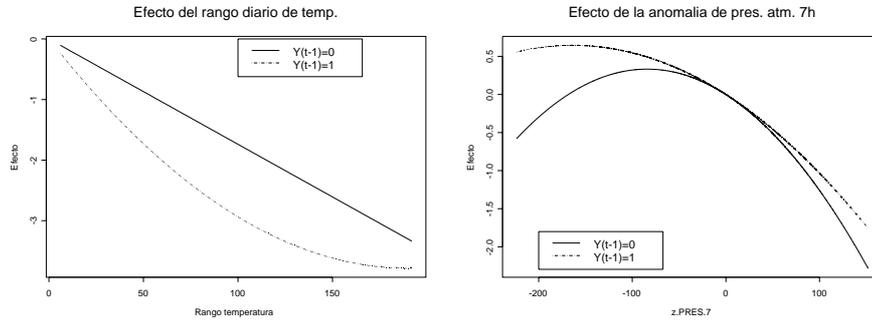


Figura 3.24: Ajuste del modelo *CM tempres* en Agoncillo. Izda.: Efecto del rango de temperatura. Dcha.: Efecto de la anomalía de presión a las 7 horas.

- El rango diario de temperatura tiene asociado un efecto negativo, como en Reinos y Tortosa. Las variaciones grandes de temperatura a lo largo del día están asociadas a situaciones anticiclónicas poco propicias para la precipitación.
- La existencia de interacción entre el rango de temperatura e  $Y_{t-1}$  supone que el efecto de esta covariable cambia. En la figura 3.24 se muestra que si no llueve en el día previo el efecto es lineal y decreciente y, si llueve, decreciente y cuadrático; un cierto valor del rango de temperatura produce un efecto más intenso si el día previo fue húmedo que si fue seco.
- Al igual que ocurre con la memoria del propio proceso, la memoria de las covariables de temperatura disminuye al incorporar la información de presión.
- Sobre el efecto de la presión atmosférica en los modelos se puede señalar que:
  - Las bajas presiones incrementan la probabilidad de lluvia, como era de esperar, dentro de una estructura compleja en la que, por ejemplo, aparecen términos cuadráticos de la presión a las 7 horas, que llegan a interaccionar con la ocurrencia previa.
  - El cambio de presión entre las 13 y las 18 horas tiene un efecto positivo. Un fuerte incremento de la presión en este intervalo, indica la existencia de presiones bajas a las 13 horas y, por lo tanto, de situaciones con alta probabilidad de ocurrencia de lluvia.

La información de la presión atmosférica se ha introducido a través de sus anomalías. Si en el modelo *CM tempres* se sustituyen dichas anomalías

Modelo	G. 1.	Nº par.	Deviance	Memoria	% var. exp.	pv HL
<i>CM hom</i>	5420	6	6000.142	4	12.0	–
<i>CM est</i>	5422	9	5926.992	3	13.3	0.907
<i>CM temp</i>	5422	14	5593.310	2	18.9	0.071
<i>CM pres</i>	5406	18	4954.385	2	29.3	0.376
<i>CM tempres</i>	5405	20	4767.963	2	32.4	0.033

Tabla 3.8: Medidas de bondad de ajuste de los modelos markovianos ajustados en Agoncillo (1978-1992).

Modelo	% días bien clasificados (0.5)				
	Global	$Y_t = 0$	$Y_t = 0$	$Y_t = 1$	$Y_t = 1$
		$Y_{t-1} = 0$	$Y_{t-1} = 1$	$Y_{t-1} = 0$	$Y_{t-1} = 1$
<i>CM hom</i>	72.2	100	20.1	0	84.1
<i>CM est</i>	72.9	100	33.2	0	77.1
<i>CM temp</i>	75.3	99.1	51.6	5.8	74.3
<i>CM pres</i>	78.4	96.2	61.3	29.7	74.0
<i>CM tempres</i>	79.5	95.5	66.5	34.6	74.3

Tabla 3.9: Porcentaje de días bien clasificados por los modelos ajustados en Agoncillo (1978-1992), según la situación observada en los días  $t$  y  $t - 1$ .

por las correspondientes covariables, se obtiene un modelo con una deviance igual a 4800.52 mayor que la del modelo presentado.

### 3.6.2 Crítica de los modelos ajustados

En la tabla 3.8 se muestran algunos estadísticos de bondad de ajuste para los cinco modelos propuestos. La información global relativa a la presión resulta ser la más influyente en la explicación de la respuesta, así lo indican los cambios en la desviación y en el porcentaje de variabilidad explicada. Notemos el mal comportamiento del estadístico de Hosmer y Lemeshow que, contrariamente a lo esperado, resulta significativo en el modelo, que según los demás criterios, mejor ajusta los datos.

El porcentaje de éxito en la clasificación de días húmedos y secos, utilizando el umbral 0.5, aumenta en los modelos complejos, ver tabla 3.9. Aunque globalmente el incremento entre el modelo más simple y el más complejo es sólo de un 7%, hay que destacar la mejora que se produce en las transiciones al estado húmedo, un indicador en el que los modelos sencillos no proporcionan ningún acierto. En los días de comienzo de racha seca, la incorporación de información climática se traduce en una mejora del porcentaje de éxito

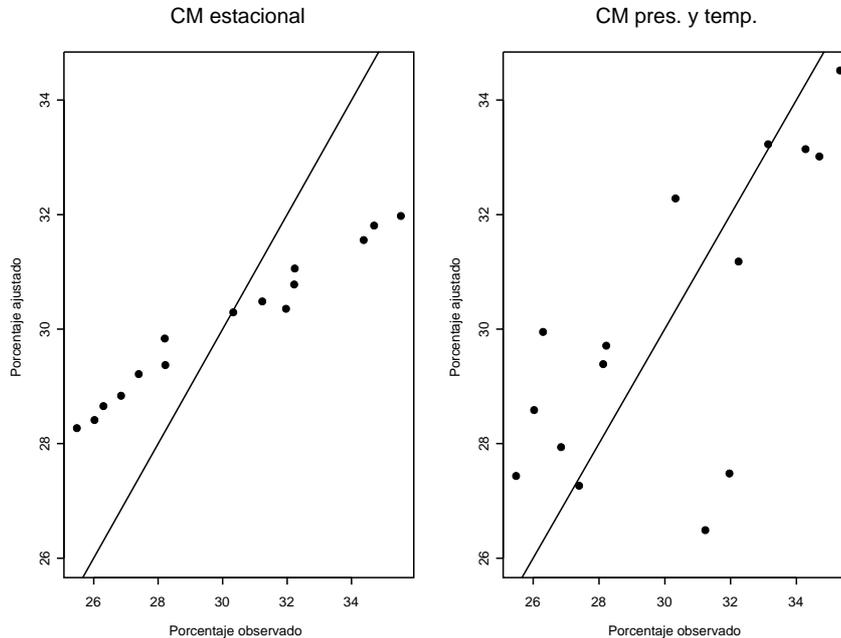


Figura 3.25: Porcentaje anual observado de días con lluvia frente al obtenido con los modelos de ocurrencia en Agoncillo (1978-1992). Izda.: CM estacional. Dcha.: CM con temperatura y presión.

que pasa de un 20% con *CM hom* a un 67% con *CM tempres*.

En la tabla 3.10 aparecen medidas que expresan la relación entre el número medio mensual de días observados de lluvia y el correspondiente valor ajustado. Los coeficiente de correlación, de eficiencia y el índice de acuerdo toman valores cercanos a 1 y sólo discriminan el modelo homogéneo.

La figura 3.25 muestra que el modelo *CM tempres* es capaz de reproducir la variabilidad interanual mientras que el modelo estacional produce frecuen-

Modelo	C. corr.	C. efic.	I. acue.	%m. err.
<i>CM hom</i>	1.00	0.66	0.83	5.78
<i>CM est</i>	0.98	0.96	0.99	0.31
<i>CM temp</i>	0.98	0.96	0.99	0.28
<i>CM pres</i>	0.97	0.94	0.98	0.26
<i>CM tempres</i>	0.98	0.95	0.99	0.23

Tabla 3.10: Medidas de bondad de ajuste basadas en la frecuencia mensual de días con precipitación para los modelos ajustados en Agoncillo (1978-1992).

Modelo	$\hat{\rho}_1$	$\hat{\rho}_2$	$\hat{p}$	$\hat{p}_0$	$\hat{p}_1$
Observado	0.332	0.153	0.3	0.201	0.533
<i>CM hom</i>	0.330	0.149	0.301	0.202	0.532
<i>CM est</i>	0.329 ( 0.014 )	0.143 ( 0.013 )	0.3 ( 0.009 )	0.201 ( 0.007 )	0.530 ( 0.011 )
<i>CM temp</i>	0.264 ( 0.016 )	0.138 ( 0.019 )	0.297 ( 0.008 )	0.218 ( 0.007 )	0.482 ( 0.013 )
<i>CM pres</i>	0.313 ( 0.013 )	0.154 ( 0.015 )	0.299 ( 0.005 )	0.205 ( 0.006 )	0.519 ( 0.009 )
<i>CM tempres</i>	0.303 ( 0.011 )	0.156 ( 0.016 )	0.298 ( 0.006 )	0.207 ( 0.005 )	0.511 ( 0.009 )

Tabla 3.11: Estadísticos obtenidos a partir de la simulación de las cadenas de Markov ajustadas en Agoncillo (1978-1992).

cias que, aunque identifican el carácter húmedo o seco de cada año, forman una nube que se alinea lejos de la bisectriz.

### 3.6.3 Distribución de la longitud de racha

Para cada modelo, salvo el homogéneo, se han simulado 20 trayectorias de longitud igual a la del periodo de estimación, utilizando las series de covariables observadas. La tabla 3.11 permite valorar el modo en que los modelos reproducen la dependencia observada en los datos, así como la frecuencia relativa de lluvia incondicional,  $\hat{p}$ , y las condicionadas a la ocurrencia en el día previo,  $\hat{p}_0$  y  $\hat{p}_1$ ;  $\hat{p}_0$  representa la frecuencia relativa de ocurrencia tras un día seco.

Las diferencias entre los estadísticos obtenidos mediante simulación y los observados son, en general, del orden de un error estándar. El modelo *CM temp* subestima la probabilidad de lluvia si el día previo es húmedo y la sobreestima si es seco; este modelo muestra también la mayor discrepancia en la autocorrelación de orden 1, que subestima.

En la tabla 3.12 aparecen algunas medidas descriptivas de las distribuciones de la longitud de racha observada y de las simuladas por los cinco modelos. Para contrastar su igualdad se ha realizado un test KS en los modelos simulados y un test chi-cuadrado en *CM hom*, de los que se incluyen los p-valores. En los modelos simulados se indica el valor medio en las 20 trayectorias y, entre paréntesis, su desviación típica.

Las conclusiones que se deducen de la comparación son:

- Los percentiles y momentos propuestos por los modelos para las rachas secas son muy semejantes a los observados, excepto los obtenidos a partir de *CM temp*. El comportamiento en las rachas húmedas es similar: el modelo con temperaturas no estima correctamente su mediana ni el rango intercuartílico.
- A la vista del resultado de los tests, se rechaza que las distribuciones de longitud simuladas con los modelos complejos sean iguales a las observadas. Sólo en *CM hom* no se rechaza la igualdad de distribución para las rachas secas.

Además de un análisis global, es necesario estudiar la capacidad de los modelos en periodos más homogéneos. Se ha realizado esa comparación para cada uno de los meses y los resultados se incluyen en las tablas A.42 a A.46. De su análisis extraemos las siguientes conclusiones:

- El modelo homogéneo muestra discrepancias significativas en las rachas secas en Marzo y en las húmedas de Agosto, cuya longitud media es la mínima observada en los 12 meses, y de Noviembre, donde la media y la dispersión son menores que en los datos observados. Los modelos con covariables, salvo *CM temp*, proporcionan p-valores no significativos al 5% para todos los meses y los dos tipos de rachas.
- En el caso de *CM temp*, el modelo produce, en los meses en que se rechaza la igualdad, rachas secas cuya longitud mediana supera en 1 día a la observada en Enero y rachas húmedas cuya distribución se concentra en valores más pequeños que los observados en Febrero, Julio y Septiembre.
- En los modelos distintos del homogéneo se encuentran discrepancias de un tamaño igual o superior a 1 día en la mediana de las rachas secas en Enero y Septiembre para *CM est*, en Enero, Junio y Agosto para *CM temp* y en Septiembre para los dos modelos con presión; en el caso de las rachas húmedas ocurre lo mismo en el mes de Junio con *CM temp* y *CM tempres*.
- Algo análogo ocurre con el rango intercuartílico; dependiendo de los modelos, las diferencias son iguales o superiores a 1 día en sólo 4 ó 5 de las 24 comparaciones. En todos los modelos con covariables se observan discrepancias de ese orden en el mes de Noviembre para las rachas húmedas y en los de Febrero y Agosto para las secas.

Rachas secas						
Modelo	$\bar{x}$	$\hat{s}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	$q_{0.95}$	pv B. aj.
Observado	4.95	5.65	3	5	15	–
<i>CM hom</i>	4.96	5.10	3	6	15	0.307
<i>CM est</i>	4.982 (0.179)	5.195 (0.335)	3 (0)	5.55 (0.51)	14.872 (0.811)	0
<i>CM temp</i>	4.58 (0.148)	4.692 (0.32)	3 (0)	4.95 (0.224)	13.815 (0.876)	0
<i>CM pres</i>	4.871 (0.134)	5.466 (0.343)	3 (0)	5.20 (0.41)	15.302 (0.728)	0
<i>CM tempres</i>	4.824 (0.124)	5.522 (0.264)	3 (0)	5.10 (0.308)	15.267 (0.923)	0
Rachas húmedas						
Modelo	$\bar{x}$	$\hat{s}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	$q_{0.95}$	pv B. aj.
Observado	2.14	1.56	2	2	6	–
<i>CM hom</i>	2.14	1.58	2	2	4	0.027
<i>CM est</i>	2.128 (0.052)	1.509 (0.07)	2 (0)	1.95 (0.224)	5 (0)	0
<i>CM temp</i>	1.931 (0.049)	1.400 (0.08)	1 (0)	1.15 (0.366)	4.815 (0.384)	0
<i>CM pres</i>	2.078 (0.038)	1.529 (0.069)	1.9 (0.308)	1.75 (0.444)	5.08 (0.255)	0
<i>CM tempres</i>	2.043 (0.038)	1.488 (0.082)	1.85 (0.366)	1.55 (0.484)	5 (0)	0

Tabla 3.12: Estadísticos de la distribución de la longitud de racha observada y obtenida con los modelos ajustados en Agoncillo (1978-1992).

- Los percentiles 90 de la longitud de racha húmeda difieren en más de 1 día en los meses de Noviembre y Diciembre en los cuatro modelos con covariables. Para las rachas secas este percentil, en general, se subestima.

### 3.6.4 Comportamiento en el periodo de validación

El comportamiento de los modelos en el periodo de validación es semejante al observado en el periodo de estimación, véase la tabla 3.13 que resume los resultados de las tablas A.47-A.51. Las medidas de bondad de ajuste son, lógicamente, algo peores pero mantienen el mismo comportamiento en cuanto a los cambios que se observan al incluir información. En el modelo

Modelo	AIC	% variab. explicada	pv HL	% días bien clasif. (0.5)
<i>CM hom</i>	2062.42	11.4	–	70.5
<i>CM est</i>	2069.24	11.2	0.003	70.8
<i>CM temp</i>	1966.10	17.1	0.003	73.5
<i>CM pres</i>	1750.94	28.1	0.069	77.4
<i>CM tempres</i>	1662.50	32.0	0.024	78.9

Tabla 3.13: Medidas de bondad de ajuste de los cinco modelos estudiados en Agoncillo, en el periodo de validación (1993-1997).

*CM tempres* se alcanza un 32% de variabilidad explicada, un valor análogo al obtenido en el periodo de estimación. El estadístico HL sigue indicando un mal ajuste de los modelos pero sus mayores p-valores se encuentran en los dos modelos que incluyen la presión atmosférica.

Los resultados del análisis de las longitudes de racha se muestran en las tablas A.53-A.57. Cabe destacar:

- El modelo *CM hom* muestra discrepancias significativas en las rachas secas en Marzo y, a diferencia de lo que ocurría en el conjunto de estimación, las rachas observadas son de longitud mayor que las teóricas. Se rechaza también la igualdad de distribuciones en los meses de Febrero, Junio y Diciembre.
- En los modelos con covariables no se rechaza, en general, la igualdad de distribución en los dos tipos de racha. Se rechaza en el caso de las rachas húmedas en Julio y Septiembre, donde la mediana pasa de valer 1 en el periodo de estimación a 2.5 y 2 días, respectivamente. Una situación parecida se produce en las rachas secas de Junio, mes en el que todos los modelos, salvo *CM temp*, proporcionan una mediana dos días menor de la observada.
- Respecto al percentil 90 de la longitud de racha húmeda encontramos la misma situación que se indicó para las medianas: se subestima en los meses de Junio y Septiembre.

## 3.7 Modelos para la ocurrencia de precipitación en el observatorio de Zaragoza

En el observatorio del aeropuerto de Zaragoza se dispone del mayor nivel de información posible; es un observatorio de primer orden con medidas en superficie a las horas tipo y dos radiosondeos diarios, lo que nos permitirá ensayar modelos en los que el predictor lineal incluya información de la troposfera.

En la subsección 3.7.1 se presentan las variables atmosféricas que aparecen por primera vez en la memoria. En 3.7.2 se muestran los modelos estimados; su grado de ajuste se estudia en la subsección 3.7.3 y la capacidad para reproducir la distribución de la longitud de las rachas se analiza en 3.7.4. Finalmente, la subsección 3.7.5 contiene la valoración del comportamiento de los modelos en el periodo de validación.

### 3.7.1 Datos disponibles

Para cada día se dispone de la información en superficie a las horas-tipo, 0h, 7h, 13h y 18h, y de las variables medidas en distintas alturas que proporcionan los radiosondeos lanzados a las 0 y 12h. La longitud del registro viene limitada por estas últimas medidas, que existen desde Agosto de 1990. Nuestro registro finaliza en Septiembre de 2000.

Las variables en superficie son la temperatura (cuyas medidas se denotan  $T00$ ,  $T07$ ,  $T13$  y  $T18$ ), la presión atmosférica ( $P00$ ,  $P07$ ,  $P13$ ,  $P18$ ), la humedad relativa ( $H00$ ,  $H07$ ,  $H13$ ,  $H18$ ) y la dirección y velocidad del viento, que se denotan  $dV13$  y  $vV07$ , por ejemplo; además se registran las temperaturas máxima y mínima diaria. La variable respuesta es la cantidad de precipitación acumulada cada día entre las 0 y las 24 horas,  $Q_t$ , a partir de la que se define la variable indicadora de ocurrencia,  $Y_t$ .

La información que proporciona el parte A del radiosondeo incluye las medidas de la altura geopotencial, la temperatura del termómetro seco, el punto de rocío, definido como la diferencia de temperaturas entre el termómetro seco y el termómetro húmedo, y la dirección y velocidad del viento, en los niveles geopotenciales 850hPa, 700hPa, 500hPa y 300hPa. Se debe señalar que, a mayor altura, mayor es el número de datos perdidos, dado que el radiosondeo se lanza adicionalmente una sola vez cuando no alcanza el nivel 500hPa en el primer intento.

La notación para describir las variables de altura se compone de unos caracteres que indican el nombre de la variable, seguidos de la altura geopotencial a la que se ha medido y, separada por un punto, la hora de la medición. Por ejemplo,  $A_{850}.12$  representa la altura del geopotencial 850hPa a las 12 horas. En la tabla 3.14 se puede ver una lista de las variables disponibles, con su notación y unidades de medida.

La información sobre la dirección del viento se va a introducir, en superficie, mediante un factor definido de acuerdo con los rumbos dominantes y, en altura, descomponiendo la dirección del viento en sus componentes Este-Oeste y Norte-Sur.

### Variables derivadas

A partir de las variables medidas se definen otras que tratan de reflejar la evolución temporal, mediante diferencias entre observaciones sucesivas, o la inestabilidad existente sobre la vertical del aeropuerto, calculando diferencias entre los valores en las distintas capas atmosféricas.

Para cada magnitud del radiosondeo, a excepción de las asociadas al viento, se definen variables que se construyen como la diferencia de los valores en los niveles geopotenciales alternos, 850-500hPa y 700-300hPa; por ejemplo:

- $T_{85/50}.12$  denota la diferencia entre la temperatura en el geopotencial 850hPa y la medida en 500hPa, a las 12 horas.
- $A_{70/30}.12$  mide el espesor de la capa entre los geopotenciales 700 y 300hPa, a las 12 horas.

Como ejemplos de variables que recogen la evolución temporal en superficie tenemos:

- $\Delta T.18.13$ , la diferencia entre la temperatura a las 18h menos la registrada a las 13 horas.
- $\Delta P.7.0$ , el cambio en la presión atmosférica entre las 0 y las 7 horas.

De esta forma se dispone, diariamente, de 91 variables, de las que 24 son derivadas, ver tabla 3.14.

### Anomalías de las variables

Las variables observadas y sus variables derivadas presentan un comportamiento estacional muy acusado en el caso de la temperatura y de la

Variables de superficie				
Precipitación	Cantidad $Q$		Ocurrencia $Y$	
Temperatura (décimas de °C)	$TMAX$		$TMIN$	
	$T18$	$T13$	$T07$	$T00$
Presión ( décimas de hPa)	$P18$	$P13$	$P07$	$P00$
Humedad (%)	$H18$	$H13$	$H07$	$H00$
Viento (Km/h)	$dV18$	$dV13$	$dV07$	$dV00$
	$vV18$	$vV13$	$vV07$	$vV00$

Diferencias entre medidas consecutivas			
$\Delta T.24.18$	$\Delta T.18.13$	$\Delta T.13.7$	$\Delta T.7.0$
$\Delta P.24.18$	$\Delta P.18.13$	$\Delta P.13.7$	$\Delta P.7.0$
$\Delta H.24.18$	$\Delta H.18.13$	$\Delta H.13.7$	$\Delta H.7.0$

Variables de radiosondeo				
Temperatura (décimas de °C)	$T850.12$	$T700.12$	$T500.12$	$T300.12$
	$T850.00$	$T700.00$	$T500.00$	$T300.00$
Altura geopotencial (metros)	$A850.12$	$A700.12$	$A500.12$	$A300.12$
	$A850.00$	$A700.00$	$A500.00$	$A300.00$
Temperatura punto rocío (décimas de °C)	$R850.12$	$R700.12$	$R500.12$	$R300.12$
	$R850.00$	$R700.00$	$R500.00$	$R300.00$

Diferencias entre medidas en alturas alternas			
$T85/50.12$	$T70/30.12$	$T85/50.00$	$T70/30.00$
$A85/50.12$	$A70/30.12$	$A85/50.00$	$A70/30.00$
$R85/50.12$	$R70/30.12$	$R85/50.00$	$R70/30.00$

Variables de viento registradas en el radiosondeo				
$dV SUP.12$	$dV850.12$	$dV700.12$	$dV500.12$	$dV300.12$
$dV SUP.00$	$dV850.00$	$dV700.00$	$dV500.00$	$dV300.00$
$vV SUP.12$	$vV850.12$	$vV700.12$	$vV500.12$	$vV300.12$
$vV SUP.00$	$vV850.00$	$vV700.00$	$vV500.00$	$vV300.00$

Tabla 3.14: Variables utilizadas en el observatorio de Zaragoza-aeropuerto.

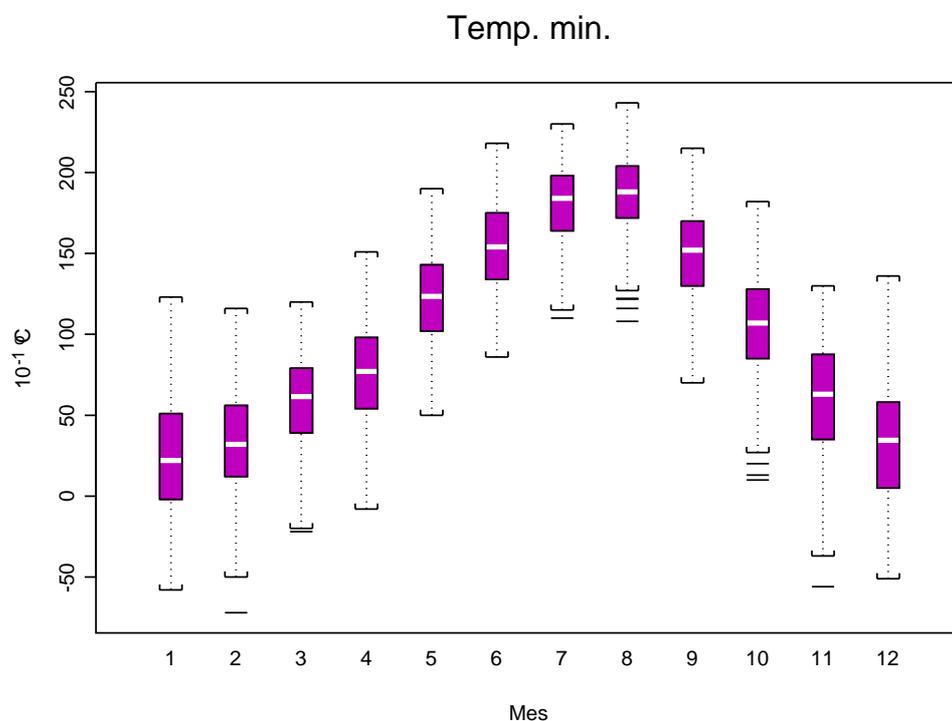


Figura 3.26: Diagramas de caja por meses de la temperatura mínima en Zaragoza (1990-2000).

precipitación y, menos destacado, en la presión atmosférica. La temperatura mínima, por ejemplo, puede tomar un valor que en Verano corresponda a una situación fresca y en Invierno a un día cálido, ver figura 3.26. Esta variable puede ser relevante en términos absolutos o en términos relativos respecto de su nivel medio en el día observado.

Las medidas de presión tienen un sentido absoluto porque identifican la presencia de una depresión o un anticiclón. Sus diferencias entre medidas consecutivas se usan como indicación de la velocidad de cambio de la situación atmosférica, por lo que tienen un sentido relativo con respecto a la posición central en cada época del año. En la figura 3.27 se muestran los perfiles suavizados de los valores diarios de la diferencia de presión entre horas tipo consecutivas, que son distintos de 0 debido a la evolución diurna y al ciclo anual en las diferencias de presión:

- El ciclo diurno de las presiones provoca que los cambios tengan media no nula; por ejemplo, un valor  $-6$  de  $\Delta P_{13.7}$  en un día de Marzo, prácticamente coincidente con su media, refleja la habitual disminución

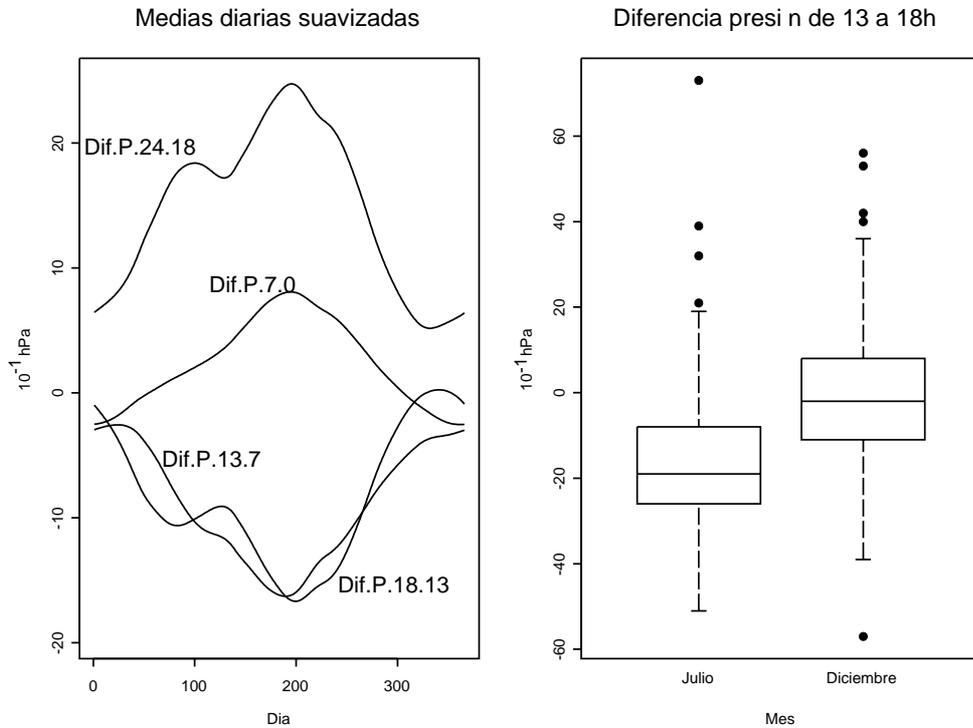


Figura 3.27: Cambios de presión entre medidas consecutivas en Zaragoza.

de la presión ligada al calentamiento de la atmósfera por insolación; el mismo valor, en el mismo día, en  $\Delta P.7.0$ , de media nula, indica una disminución apreciable de la presión.

- El ciclo anual es distinto para las 4 medidas horarias de presión y el valor medio de las diferencias tiene un comportamiento estacional. En la figura 3.27 se observa que un valor -20, que corresponde a la mediana de  $\Delta P.18.13$  en Julio, es un valor pequeño en Diciembre.

De los hechos anteriores se concluye que es conveniente definir anomalías de las diferencias entre presiones con respecto a su nivel medio diario. En consecuencia, la variable  $z.\Delta P.18.13$  se define como la diferencia entre  $\Delta P.18.13$  y su valor medio en el día correspondiente, que se obtiene ajustando un modelo de regresión cuyos predictores son los armónicos hasta el orden 4.

Por motivos análogos, y de la misma forma, se definen anomalías para todas las variables, salvo las de viento. Esas anomalías se denotan con el nombre de la variable precedido por la letra  $z$ ; por ejemplo,  $z.T18$  ó  $z.T85/50.12$ .

En la notación, los subíndices  $t$ ,  $t - 1$  ó  $t - 2$  indican si la covariable está

medida en el día cuya precipitación se ajusta, o corresponde a una magnitud del día previo ( $P18_{t-1}$ ) o de dos días antes ( $H13_{t-2}$ ).

### Datos de viento

La información sobre el viento observado en las distintas alturas se registra mediante dos variables: dirección y velocidad. La primera se expresa en decenas de grados según el origen del viento registrado: a las direcciones Norte, Este, Sur y Oeste les corresponden los ángulos  $0^\circ$ ,  $90^\circ$ ,  $180^\circ$  y  $270^\circ$ , respectivamente. Dado su carácter circular, la caracterización en los niveles geopotenciales se ha hecho utilizando el seno y el coseno del ángulo. Así se definen, por ejemplo, las variables  $dV500.12.cos$  y  $dV500.12.sen$ , que admiten una interpretación en términos de componentes Este-Oeste y Norte-Sur y permite analizar fácilmente el efecto de la dirección del viento en el predictor lineal.

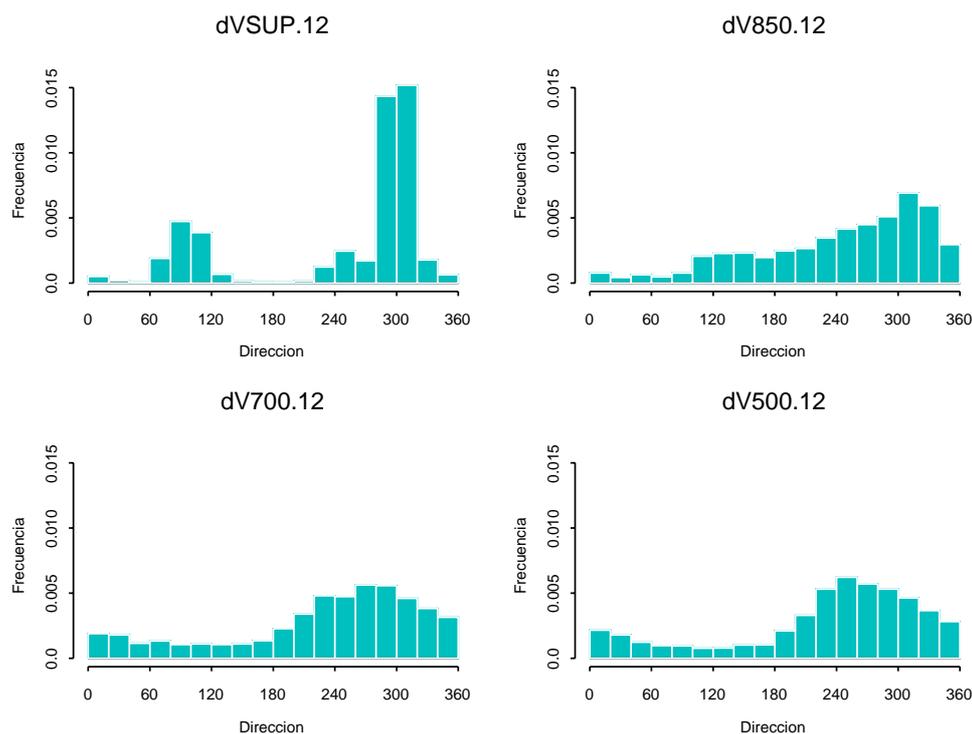


Figura 3.28: Frecuencia relativa de direcciones de viento en Zaragoza (1990-2000).

El flujo dominante de la circulación atmosférica, de Oeste a Este, explica la distribución observada de la dirección del viento en superficie y en altura, ver figura 3.28. Debido a las características geográficas del Valle del Ebro,

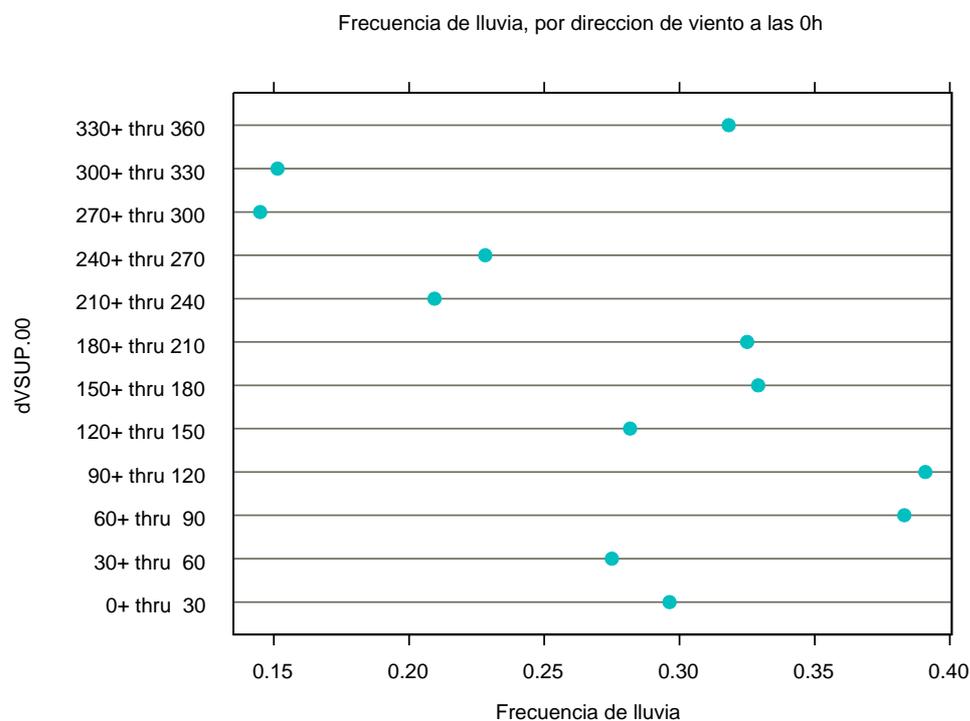


Figura 3.29: Frecuencia relativa de ocurrencia de precipitación según la dirección del viento en superficie a las 0 horas, Zaragoza (1990-2000).

existe un predominio, en superficie, del viento de procedencia NW, denominado *cierzo*, y del de dirección SE, llamado *bochorno*, siendo la frecuencia de otros rumbos mucho menor. Por esta razón se ha buscado una partición del viento en superficie, según su procedencia.

Su distribución de frecuencias nos ha llevado a definir la partición siguiente:

- Calma: velocidad de 0 Km/hora,
- Este: direcciones entre  $45^\circ$  y  $184^\circ$ ,
- Suroeste: direcciones entre  $185^\circ$  y  $244^\circ$ ,
- Noroeste: direcciones entre  $245^\circ$  y  $344^\circ$ ,
- Norte: direcciones entre  $345^\circ$  y  $44^\circ$ .

La partición anterior se estableció siguiendo las orientaciones de meteorólogos conocedores de la región, atendiendo a un análisis exploratorio del viento en

superficie y a su relación con la ocurrencia de precipitación. En la figura 3.29 se aprecia que la frecuencia de lluvia varía según la dirección del viento, fenómeno bien conocido, García de Pedraza (1985) [43].

Aunque el criterio habitual en Meteorología es definir la situación de calma asociada a una velocidad del viento inferior a 5 Km/h, Tudela (1999) [111], hemos optado por definir ese estado con la velocidad 0 Km/h, debido a que los modelos pueden introducir información de velocidad.

Dada la gran cantidad de información disponible asociada a las variables de viento, se ha decidido utilizar en los modelos únicamente las variables en superficie y altura proporcionadas por el parte A del radiosondeo a las 0 y 12 horas.

### 3.7.2 Modelos ajustados

Los modelos se han estimado utilizando los datos del periodo 1990 a 1997 y se han reservado para su validación los del periodo 1998-2000. En las tablas comprendidas entre A.58 y A.61 se muestra la composición de los predictores lineales de los modelos ajustados, los coeficientes de los términos significativos y su correspondiente error estándar. Entre los modelos ensayados están los que permiten la comparación con otros observatorios, *CM hom*, *CM est*, *CM temp* y *CM pres*. Se construye el modelo *CM temp hor* basado en las medidas horarias de temperatura. El modelo denominado *CM superficie* utiliza las medidas horarias de temperatura y de presión y el denotado *CM tempreshum* incluye, además, las de la humedad en superficie.

La información del radiosondeo se introduce progresivamente sobre el modelo *CM tempreshum*. El modelo más completo se denomina *CM sondeos* e incluye toda la información de los dos radiosondeos. Finalmente, se ajusta un modelo no causal que incorpora la información de los valores de las covariables registradas en el día  $t + 1$ , con el que se pretende tener una referencia sobre el grado de ajuste alcanzable con esta información.

Se ha ajustado un modelo que agrega a las medidas de superficie las del radiosondeo a las 12h y que no emplea covariables de viento, denotado *CM Down*, y otro que usa también esa información, *CM Down-viento*, para valorar el grado de ajuste que se alcanza, usando datos observados, con un nivel de información análogo al procedente del GCM que se utilizará para el downscaling en el capítulo 5.

En la construcción de los modelos se aplicó la estrategia de introducción

de covariables siguiente:

- A partir del modelo estacional, las covariables de superficie se introducen en el orden: temperatura, presión y, por último, humedad. Para cada una de ellas se analiza la necesidad de incluir en el modelo:
  1. las medidas horarias empezando por las de las 0 horas y finalizando con las de las 18 horas,
  2. las variables que representan los cambios entre medidas consecutivas,
  3. las anomalías correspondientes a todas las variables anteriores,
  4. finalmente, los términos de interacción de todas esas variables con los indicadores de ocurrencia pasada presentes en el modelo.
  
- Las variables relativas a la troposfera se introducen siguiendo el orden: temperatura, altura geopotencial y temperatura del punto de rocío. Para cada una de ellas se analiza la significación de su medida a las 12 y posteriormente a las 0 horas. Para cada una de ellas se analiza el interés de introducir:
  1. el valor de la variable en el geopotencial 850, 700, 500 y 300hPa,
  2. las variables diferencia que miden el cambio entre las capas 850-500 y 700-300hPa,
  3. las anomalías correspondientes a todas las variables anteriores,
  4. las interacciones de todas esas variables con los indicadores de lluvia presentes en el modelo.
  
- En cuanto a la información del viento, se analiza primero el efecto del viento a las 12 y luego el correspondiente a las 0 horas; en ambos casos:
  1. se analiza la inclusión del viento en superficie, a través del factor que clasifica las direcciones y se consideran las interacciones de ese factor con la velocidad,
  2. se analiza el efecto de las variables que definen la dirección y velocidad del viento en las alturas geopotenciales 850, 700, 500 y 300hPa,
  3. se estudia la existencia de interacciones entre el factor de viento en superficie y las distintas variables de viento en altura.

En cualquiera de las etapas, si se incluye una covariable, se analiza la significación de su efecto cuadrático. Una vez logrado el modelo completo se procede a una fase de simplificación que se explicó en la subsección 3.3.1.

El análisis de los predictores lineales de los modelos ajustados permite establecer algunas conclusiones:

- El efecto de la ocurrencia de lluvia en el día previo es significativo en todos los modelos, aunque con distinto grado de relevancia. En términos absolutos, el estadístico  $t$  asociado a  $Y_{t-1}$  es el más importante en los modelos sin covariables climáticas, se encuentra en cuarto lugar en los modelos con temperatura o presión y su importancia es menor cuando se introducen otras covariables. La memoria requerida del proceso disminuye cuando se introduce información climática, reduciéndose a orden 1 con la intervención de la presión atmosférica.
- Los términos armónicos no son necesarios cuando en el predictor lineal hay información sobre la presión en superficie.
- En todos los modelos con información de temperatura resulta significativa la variación de la misma a lo largo del día, que puede estar representada por el rango o por la variable *cambio.T*, construida como  $T18 + T13 - T07 - T00$ .
- A partir de las medidas de presión en las horas tipo se define una variable denominada *cambio.presion* que resume su efecto y se calcula como  $P18 + P00 - P13 - P07$ . Es una medida de la variación de la presión atmosférica a lo largo del día.
- La humedad en superficie interviene a través de sus anomalías a las 7, 13 y 18 horas, reunidas en una combinación lineal donde se ponderan doblemente las anomalías de las 7 y las 18 horas.
- El incremento de parámetros en los dos modelos con información de la troposfera se debe, principalmente, a la inclusión del viento en altura, que requieren, respectivamente, 6 términos, 4 de ellos relativos a la dirección de viento en 500hPa, y 8 términos el otro, 6 ligados también a  $dV500.12$ . Estos modelos se ajustan con un número menor de datos porque, como se comentó en el apartado 3.7.1, las medidas del radiosondeo no existen algunos días. El porcentaje de variabilidad explicada por el modelo causal más complejo alcanza un 49%.

Modelo	G. l.	N. par.	Deviance	%var. exp.	pv HL
<i>CM hom</i>	2705	4	2708.821	7.7	—
<i>CM est</i>	2700	9	2685.263	8.5	0.258
<i>CM temp</i>	2703	6	2430.711	17.9	0.248
<i>CM tempchor</i>	2700	9	2327.155	21.6	0.706
<i>CM pres</i>	2704	6	2288.861	23.6	0.127
<i>CM superficie</i>	2700	10	2072.427	30.9	0.613
<i>CM tempreshum</i>	2701	9	1789.104	41.8	0.473
<i>CM Down</i>	2399	9	1532.247	44.9	0.617
<i>CM Down-viento</i>	2324	16	1428.809	47.1	0.706
<i>CM sondeos</i>	2153	20	1273.797	49.0	0.504
Modelo no causal	2030	22	1113.992	53.45	0.930

Tabla 3.15: Medidas de bondad de ajuste para los modelos de ocurrencia ajustados en Zaragoza (1990-1997).

### 3.7.3 Bondad de ajuste

Las tablas 3.15 a 3.17 muestran información sobre el grado de ajuste de los distintos modelos. El estadístico HL no se calcula para el modelo homogéneo porque ajusta sólo 4 probabilidades diferentes.

La menor memoria del proceso de ocurrencia en Zaragoza se explica por la menor longitud del registro. Las probabilidades ajustadas por *CM hom* clasifican todos los días como secos, por lo que el porcentaje de días bien clasificados corresponde con el de días sin precipitación.

Los modelos que utilizan sólo las covariables de superficie se ajustan con el mismo tamaño de muestra, por lo que sus desviaciones son comparables. La tabla 3.15 muestra que las covariables que se incluyen progresivamente son relevantes en la mejora de los modelos; destaca la disminución de la desviación asociada a la introducción de las temperaturas, un 13% respecto a *CM est*, la debida a la presión, un 15% respecto a *CM temp*, y a la humedad en superficie, un 13.7% respecto a *CM superficie*. Esta mejora en la desviación se refleja en el incremento de variabilidad explicada.

El aumento de información proporciona una mejora paulatina del porcentaje de días iniciales de racha húmeda correctamente clasificados; se alcanza un 45% en *CM tempreshum*, mientras que la adición de covariables de altura sólo lo mejora un 8%, ver tabla 3.16. La proporción de días bien clasificados entre los húmedos que siguen a un día húmedo alcanza un 68.7% en *CM tempreshum* y un 73.6% en *CM sondeos*, destacando el incremento que

Modelo	Global	%días bien clasificados (0.5)			
		$Y_t = 0$ $Y_{t-1}=0$	$Y_t = 0,$ $Y_{t-1}=1$	$Y_t = 1$ $Y_{t-1}=0$	$Y_t = 1$ $Y_{t-1}=1$
<i>CM hom</i>	77.3	100	100	0	0
<i>CM est</i>	77.3	100	84.1	0	20.1
<i>CM temp</i>	79.7	99.4	74.8	6.3	52.6
<i>CM temp hor</i>	80.6	98.3	76.3	15.8	53.7
<i>CM pres</i>	80.9	98.1	78.9	20.5	50.0
<i>CM superficie</i>	82.8	96.9	79.8	33.1	59.0
<i>CM tempreshum</i>	85.8	97.4	80.9	45.8	68.7
<i>CM Down</i>	86.7	97.1	81.9	51.1	74.0
<i>CM Down-viento</i>	86.3	96.1	83.1	51.1	73.9
<i>CM sondeos</i>	86.9	96.5	83.0	53.7	73.6
Modelo no causal	88.8	96.5	84.4	62.2	80.1

Tabla 3.16: Porcentaje de días bien clasificados por los modelos de ocurrencia ajustados en Zaragoza (1990-1997).

supone la adición de la temperatura, un 30% respecto al modelo estacional. Como ocurría en los otros observatorios, los modelos no son completamente satisfactorios caracterizando las transiciones de racha seca a húmeda pero los modelos con información del radiosondeo clasifican correctamente más de la mitad de estos días.

La reproducción de las características agregadas puede considerarse adecuada incluso en los modelos sin covariables climáticas. El número de días de precipitación observado y ajustado en cada mes son muy semejantes, ver figura 3.30. La mayor discrepancia entre valores ajustados y observados se produce en el mes de Mayo en tres de los modelos. El modelo con información del radiosondeo no presenta ese sesgo y se aleja más en Marzo, mes en el que la frecuencia de lluvia observada es sensiblemente menor. Las medidas definidas para valorar el grado de ajuste de la frecuencia mensual, se muestran en la tabla 3.17.

Los valores del coeficiente de correlación son, en todos los casos, elevados y no discriminan entre los distintos modelos; se da la circunstancia de que su mayor valor se alcanza en *CM hom*. El resto de los índices tiene escasa utilidad; mejoran cuando se introduce información adicional, asignando el peor valor a *CM hom* y uno de los mejores al modelo con más información.

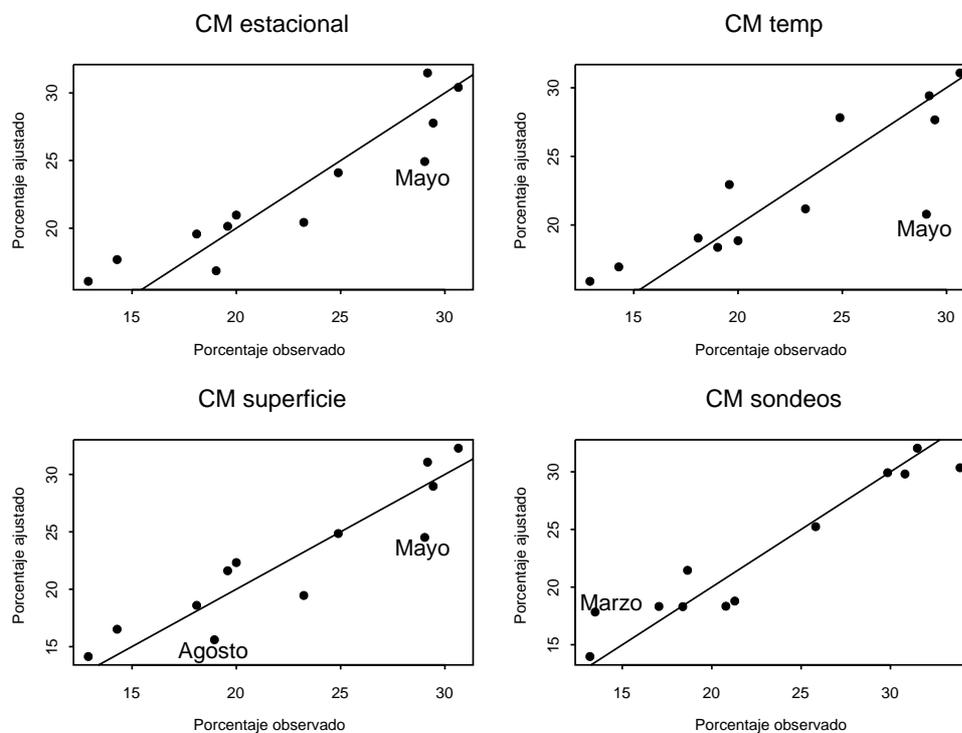


Figura 3.30: Porcentaje mensual de días de precipitación observado y ajustado en Zaragoza, según distintos modelos.

Modelo	Coef. correl.	C. eficiencia	I. acuerdo	%medio error
<i>CM hom</i>	0.995	0.512	0.712	6.159
<i>CM est</i>	0.924	0.847	0.954	2.067
<i>CM temp</i>	0.851	0.724	0.916	2.155
<i>CM temphor</i>	0.897	0.804	0.942	1.973
<i>CM pres</i>	0.869	0.727	0.902	3.523
<i>CM superficie</i>	0.916	0.834	0.956	0.854
<i>CM tempreshum</i>	0.895	0.790	0.932	2.812
<i>CM Down</i>	0.915	0.827	0.946	2.288
<i>CM Down-viento</i>	0.955	0.904	0.972	1.910
<i>CM sondeos</i>	0.955	0.904	0.972	1.921
Modelo no causal	0.946	0.894	0.970	1.392

Tabla 3.17: Medidas de bondad de ajuste basadas en la frecuencia mensual de días con precipitación para los modelos ajustados en Zaragoza (1990-1997).

### Comportamiento por estaciones

Dada la información disponible y teniendo en cuenta que en el régimen de lluvia mediterráneo la precipitación en las distintas estaciones está provocada por diferentes tipos de situación atmosférica, vamos a desglosar por estaciones el análisis comparativo de los modelos.

Para simplificar la exposición se presentan las características más importantes de los modelos *CM hom*, *CM est*, *CM temp*, *CM superficie*, que permiten la comparación entre observatorios, y de *CM sondeos* que supone un cambio cualitativo en la información que incorpora. Las medidas de evaluación se han incluido en las tablas A.62 a A.66 y, en forma resumida, en la tabla 3.18. Destacamos en particular que:

- Las medidas de bondad de ajuste del modelo *CM hom* son algo peores que las de *CM est* y las de éste, a su vez, bastante peores que las de los modelos que incluyen alguna covariable climática. Los dos modelos más sencillos no clasifican correctamente ningún día inicial de racha húmeda, lo que nos lleva a concluir que son insuficientes para representar la precipitación en Zaragoza.
- El modelo *CM temp* mejora al estacional especialmente en Otoño e Invierno, como indican los incrementos del índice relativo de Brier y del porcentaje %NAS. En Primavera, la inclusión de la temperatura supone una mejora poco importante de %NAS, mientras en Verano destaca el valor bajo de este índice y el hecho de que no se incremente el porcentaje de días bien clasificados.
- La introducción de la presión en superficie tiene su mayor impacto en Primavera y Verano, las estaciones en las que la inclusión de la temperatura es menos útil. En todas las estaciones aumenta de forma considerable el porcentaje de clasificación correcta de los días iniciales de racha húmeda, que toma su mayor valor en Otoño (40.7%) y el mínimo en Verano (23.5%).
- El modelo *CM sondeos* explica más del 50% de la variabilidad en las estaciones de Primavera y Otoño, donde los valores del porcentaje %NAS son también superiores al 50%. El Verano y el Invierno son peor ajustados por este modelo, que en Invierno alcanza su menor porcentaje de variabilidad explicada.
- En los modelos con información de superficie, los porcentajes %NAS y de clasificación correcta de los días iniciales de racha húmeda son en

Modelo	Deviance	Índice rel. Brier	pv HL	% días bien clasificados	
				Global	%NAS
Primavera					
<i>CM hom</i>	605.70	10.37	–	78.88	0
<i>CM est</i>	601.42	10.93	0.342	79.19	15.72
<i>CM temp</i>	537.96	19.84	0.378	82.3	22.45
<i>CM superficie</i>	421.67	37.92	0.166	84.63	38.89
<i>CM sondeos</i>	269.67	54.01	0.520	89.07	58.45
Verano					
<i>CM hom</i>	571.98	6.79	–	83.23	0
<i>CM est</i>	568.44	7.09	0.279	83.38	4.27
<i>CM temp</i>	525.82	13.84	0.336	82.94	9.45
<i>CM superficie</i>	432.34	30.06	0.426	87.11	28.69
<i>CM sondeos</i>	274.19	48.21	0.384	89.54	46.73
Otoño					
<i>CM hom</i>	813.20	3.63	–	73.90	0
<i>CM est</i>	803.02	4.62	0.573	72.94	4.83
<i>CM temp</i>	709.33	17.44	0.057	78.02	27.93
<i>CM superficie</i>	614.79	29.05	0.708	79.81	38.75
<i>CM sondeos</i>	337.74	51.49	0.502	87.02	57.74
Invierno					
<i>CM hom</i>	717.95	8.13	–	73.45	0
<i>CM est</i>	712.37	9.06	0.099	73.91	7.49
<i>CM temp</i>	657.61	17.3	0.427	75.72	25.81
<i>CM superficie</i>	603.63	25.91	0.224	79.79	37.96
<i>CM sondeos</i>	392.2	41.33	0.014	82.07	46.11

Tabla 3.18: Medidas de bondad de ajuste, por estaciones, de cinco modelos seleccionados, Zaragoza (1990-1997).

Verano inferiores en un 10% a los de las otras estaciones. La incorporación de las variables de altura corrige este hecho y hace que en Verano se alcancen valores superiores a los de Invierno.

Se concluye que el grado de ajuste está asociado al tipo de precipitación dominante en cada época del año. Todos los modelos caracterizan mejor las dos estaciones húmedas, Primavera y Otoño, en las que son más frecuentes las precipitaciones ligadas a frentes nubosos. El Verano, con precipitaciones mayoritariamente de carácter convectivo, es la estación peor representada por los tres modelos más sencillos; la utilización de la presión hace que el porcentaje de variabilidad explicada supere al obtenido en Invierno, estación en la que la información de presión y altura produce una mejora menos relevante.

### 3.7.4 Distribución de la longitud de racha

En esta subsección se analiza la mejora que la incorporación de información supone en la reproducción de la distribución de las longitudes de racha. Se presentan los resultados correspondientes a los cinco modelos seleccionados.

La distribución de la longitud de las rachas secas y húmedas para los modelos con covariables se ha obtenido a partir de 20 secuencias simuladas para cada modelo.

En la tabla 3.19 se muestran estadísticos que caracterizan el comportamiento de la serie temporal de ocurrencia: los coeficientes de autocorrelación de orden 1 y 2, la frecuencia relativa de ocurrencia tras un día seco ( $\hat{p}_0$ ), tras uno húmedo ( $\hat{p}_1$ ) y la frecuencia global ( $\hat{p}$ ). Junto a cada valor estimado, obtenido como media en las 20 simulaciones, se incluye, entre paréntesis, el error estándar correspondiente. Todos los modelos reproducen adecuadamente estas características globales, salvo *CM temp* que subestima los valores de  $\hat{p}_1$  y  $\hat{p}$ . En cuanto a la variabilidad de las estimaciones, el error estándar no muestra ningún comportamiento sistemático.

En la figura 3.31 aparecen el correlograma observado y los obtenidos a partir de los modelos *CM est* y *CM sondeos*. La figura muestra que el modelo simple reproduce bien las autocorrelaciones hasta el orden 3 y que proporciona valores prácticamente nulos en los retardos posteriores. *CM sondeos* reproduce bien las dos primeras autocorrelaciones y, en los retardos posteriores, sus valores oscilan dentro del rango de variación de los observados.

En la tabla 3.20 se muestran los valores observados y las estimaciones de

Modelo	$\hat{\rho}_1$	$\hat{\rho}_2$	$\hat{\rho}$	$\hat{\rho}_0$	$\hat{\rho}_1$
Observado	0.270	0.129	0.227	0.166	0.436
<i>CM hom</i>	0.267 ( 0.019 )	0.133 ( 0.028 )	0.23 ( 0.014 )	0.168 ( 0.012 )	0.436 ( 0.017 )
<i>CM est</i>	0.275 ( 0.022 )	0.129 ( 0.021 )	0.223 ( 0.011 )	0.161 ( 0.008 )	0.436 ( 0.021 )
<i>CM temp</i>	0.207 ( 0.025 )	0.111 ( 0.021 )	0.223 ( 0.009 )	0.177 ( 0.011 )	0.384 ( 0.017 )
<i>CM superficie</i>	0.258 ( 0.019 )	0.112 ( 0.024 )	0.227 ( 0.008 )	0.168 ( 0.004 )	0.427 ( 0.020 )
<i>CM sondeos</i>	0.262 ( 0.028 )	0.125 ( 0.021 )	0.23 ( 0.009 )	0.169 ( 0.009 )	0.431 ( 0.023 )
Modelo no causal	0.25 ( 0.027 )	0.141 ( 0.025 )	0.236 ( 0.006 )	0.177 ( 0.007 )	0.427 ( 0.021 )

Tabla 3.19: Estadísticos relativos a la serie de ocurrencia observados y estimados mediante simulación, Zaragoza (1990-1997).

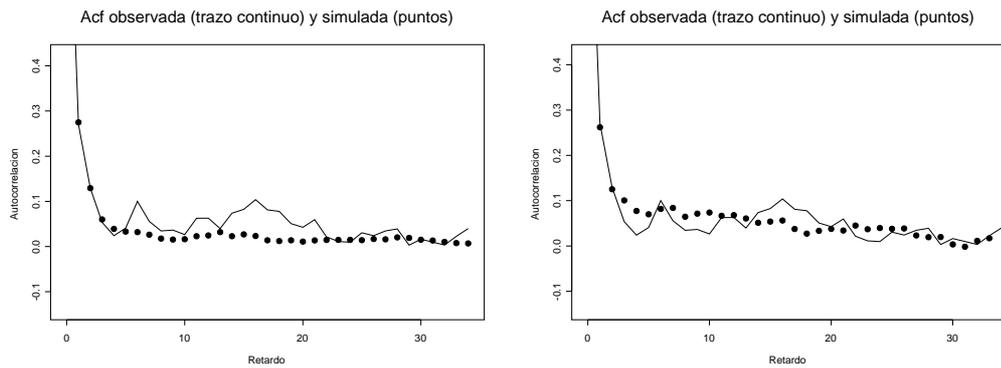


Figura 3.31: Correlograma de la serie de ocurrencia observada y autocorrelaciones estimadas con *CM est*, izda., y *CM sondeos*, dcha., Zaragoza (1990-1997).

Rachas secas							
Modelo	$\bar{x}$	$\hat{s}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	$q_{0.95}$	pv KS	pv Wilc.
Observado	5.813	6.763	4	6	13.35	–	–
<i>CM hom</i>	5.98	5.81	4	6	18	0.259 <sup>(1)</sup>	–
<i>CM est</i>	6.206 (0.314)	6.303 (0.51)	4.1 (0.308)	6.338 (0.804)	18.772 (1.254)	0.018	0.003
<i>CM temp</i>	5.665 (0.332)	5.789 (0.559)	3.75 (0.444)	5.762 (0.535)	17.362 (1.823)	0.056	0.015
<i>CM superficie</i>	5.952 (0.132)	6.528 (0.427)	3.85 (0.366)	5.438 (0.486)	18.422 (1.45)	0.032	0.009
<i>CM sondeos</i>	5.892 (0.305)	6.667 (0.583)	3.525 (0.499)	5.475 (0.595)	19.227 (2.126)	0.033	0.014
Modelo no causal	5.668 (0.241)	6.777 (0.594)	3.3 (0.47)	5.5 (0.59)	18.092 (1.832)	0.056	0.016
Rachas húmedas							
Modelo	$\bar{x}$	$\hat{s}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	$q_{0.95}$	pv KS	pv Wilc.
Observado	1.649	1.099	1	1	3	–	–
<i>CM hom</i>	1.77	1.21	1	1	4	0.761 <sup>(1)</sup>	–
<i>CM est</i>	1.773 (0.069)	1.287 (0.124)	1 (0)	1 (0)	4.198 (0.405)	0	0
<i>CM temp</i>	1.622 (0.045)	1.104 (0.085)	1 (0)	1 (0)	3.865 (0.332)	0	0
<i>CM superficie</i>	1.748 (0.06)	1.183 (0.111)	1 (0)	1 (0)	4.15 (0.366)	0	0
<i>CM sondeos</i>	1.764 (0.076)	1.273 (0.124)	1 (0)	1 (0)	4.155 (0.336)	0	0
Modelo no causal	1.749 (0.064)	1.268 (0.099)	1 (0)	1 (0)	4.117 (0.294)	0	0

<sup>(1)</sup> Se usa un test chi-cuadrado.

Tabla 3.20: Estadísticos de la distribución de la longitud de racha, observados y obtenidos con distintos modelos, Zaragoza (1990-1997).

algunos estadísticos asociados a la distribución de la longitud de las rachas secas y húmedas. En las dos últimas columnas se incluyen los p-valores de los tests KS y de Wilcoxon que contrastan la igualdad de distribuciones; en el caso del modelo homogéneo se realiza un test chi-cuadrado.

Las rachas húmedas observadas en Zaragoza corresponden mayoritariamente a días de lluvia aislada, como lo indica el valor mediano igual a 1 y el rango intercuartílico. Éste es un hecho bien reproducido por todos los modelos que, sin embargo, tienden a generar valores mayores que los observados para las rachas húmedas más prolongadas. El modelo *CM temp* es el que proporciona estadísticos más cercanos a los observados pero los tests indican que no se puede considerar que ninguno de los modelos reproduzca adecuadamente la distribución.

En cuanto a las rachas secas, la distribución obtenida a partir de las simulaciones tampoco se corresponde con el régimen observado, aunque hay que destacar que el test KS tiene un p-valor mayor que 0.05 en *CM temp* y en el modelo no causal. El modelo con información del radiosondeo presenta la media y desviación típica más semejantes a las observadas, aunque no ocurre así en los percentiles. Todos los modelos sobreestiman el percentil 95, produciendo valores superiores a 17 días.

Si se atiende a la reproducción de la longitud de ambos tipos de racha en cada mes, puede decirse que, en general, la hipótesis de igualdad de distribuciones no se rechaza, ver tablas A.68 a A.72. Las excepciones se encuentran en las rachas húmedas de Enero y Diciembre, con *CM hom*, y en las secas de Diciembre con *CM sondeos*.

Respecto a las rachas secas, cabe señalar que *CM hom* produce un valor mediano de 4 días, que discrepa en un día o más del valor observado, en 11 meses. Esto sólo ocurre en 3 meses con *CM est*, que además es el modelo que asocia valores más próximos a los observados en los meses de Abril y Diciembre, y en 6 meses con *CM sondeos*. Como ilustración, en las figuras 3.32 y 3.33 se comparan los percentiles observados y simulados con los modelos *CM est* y *CM sondeos*, respectivamente, en el mes de Diciembre, donde *CM sondeos* sobreestima tanto la mediana como el percentil 90. Se producen discrepancias mayores que el 30% del valor observado en la estimación del rango intercuartílico en cuatro meses con *CM est* y *CM sondeos* y en más meses con los otros modelos.

En relación con las rachas húmedas, cabe señalar que existen algunas discrepancias comunes a todos los modelos; así, producen errores superiores

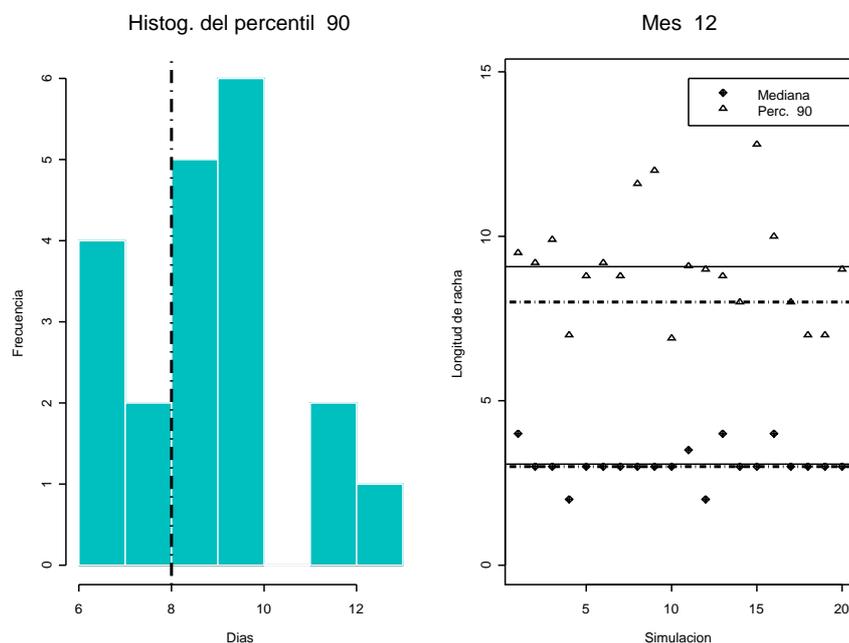


Figura 3.32: Percentiles de la distribución de la longitud de racha seca en Diciembre: datos observados y simulados a partir de *CM est*.

al 30% del valor mediano observado en tres meses al menos. Simulan una longitud mediana de 1 día frente a un valor observado de 2 días en los meses de Abril y de Agosto, aunque en éste es *CM sondeos* el modelo que proporciona la mejor aproximación, 1.25 días. El rango intercuartílico de las rachas observadas en Enero y Mayo, 2 días, y en Julio, 0.5 días, se diferencia en más de un 30% del valor generado por cualquiera de los modelos; en Octubre esto se produce en todos los modelos salvo en *CM sondeos*. En las figuras 3.34 y 3.35 se muestran los percentiles observados y simulados con *CM temp* y *CM sondeos* de la longitud de las rachas húmedas en Mayo; se aprecia que reproducen adecuadamente la longitud mediana pero subestiman el percentil 90.

### 3.7.5 Comportamiento en el periodo de validación

En la tabla 3.21 se muestran las medidas de bondad de ajuste de los modelos propuestos en los datos reservados para validación, periodo 1998-2000. Cada modelo reproduce las propiedades analizadas en un grado similar al que lo hacía en los datos de estimación, con medidas de bondad de ajuste, en líneas generales, algo peores.

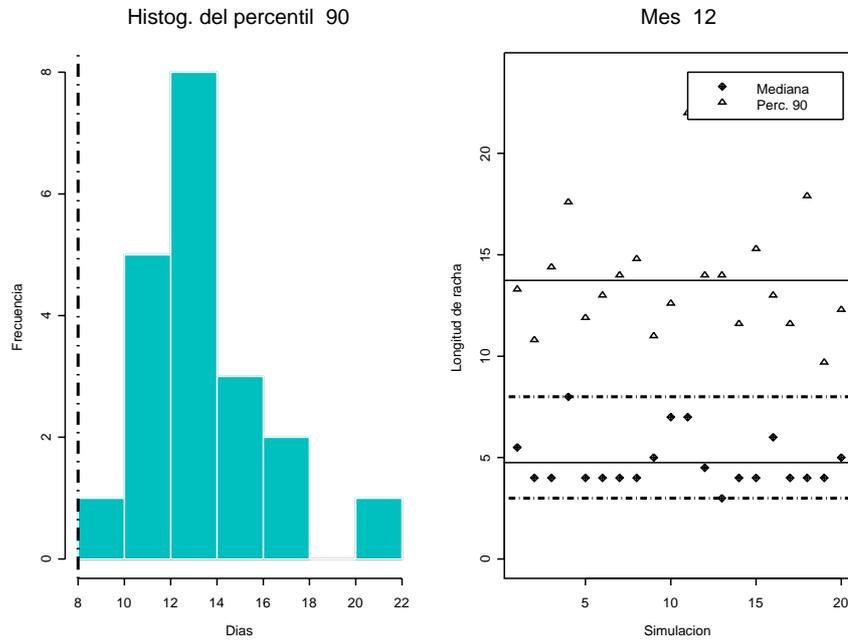


Figura 3.33: Percentiles de la distribución de la longitud de racha seca en Diciembre: datos observados y simulados a partir de *CM sondeos*.

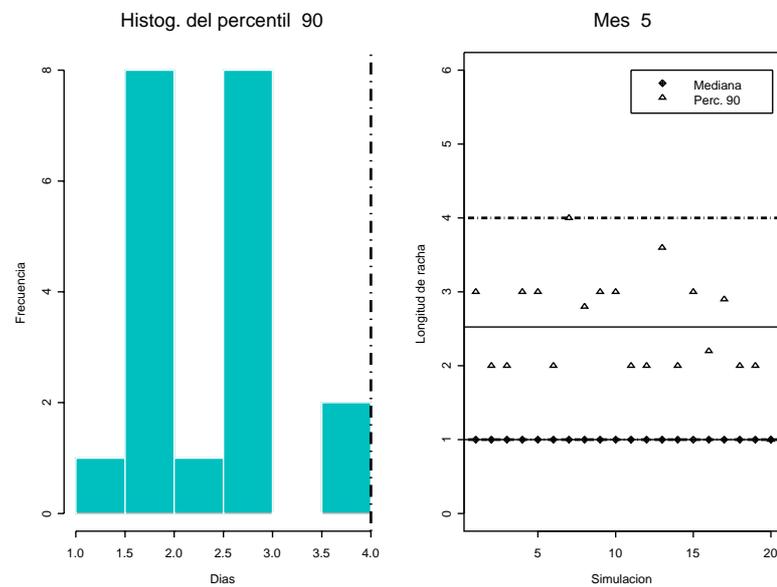


Figura 3.34: Percentiles de la distribución de la longitud de racha húmeda en Mayo: datos observados y simulados a partir de *CM temp*.

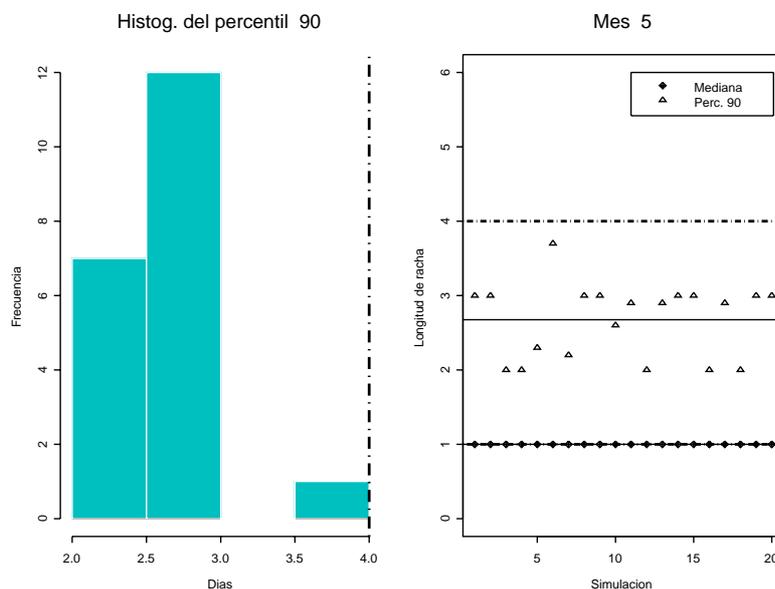


Figura 3.35: Percentiles de la distribución de la longitud de racha húmeda en Mayo: datos observados y simulados a partir de *CM sondeos*.

Si se comparan los resultados en ambos periodos, ver tabla 3.15, las mayores diferencias en el porcentaje de variabilidad explicada se encuentran en el modelo con temperaturas horarias, un 4.3% menor, y en el modelo no causal, un 6.5% menor. Las diferencias son más pequeñas en el porcentaje de días bien clasificados, en el que las variaciones se encuentran en un intervalo de un 1%. El test de Hosmer-LESmeshow se rechaza al 5% en 4 de los 11 modelos ajustados, entre ellos el modelo estacional y el modelo con más información.

### Distribución de la longitud de racha

En las tablas A.78-A.83 se recogen los resultados del análisis de las distribuciones de longitud de racha en el periodo de validación. El modelo homogéneo, a diferencia de lo que ocurría en el periodo de estimación, no reproduce la distribución observada en las rachas húmedas cuando se analiza la totalidad del periodo.

El análisis mensual indica, en general, que no se puede rechazar la hipótesis de igualdad de distribuciones, lo que puede deberse al pequeño tamaño del conjunto de datos utilizado, ya que existen discrepancias importantes en algunas características de las rachas secas, en bastantes meses, en una mayoría de los modelos.

Modelo	AIC	% var. exp.	pv HL	% días bien clasif. (0.5)
<i>CM hom</i>	1022.0	4.7	–	78.0
<i>CM est</i>	1030.2	4.9	0.038	77.3
<i>CM temp</i>	940.9	14.4	0.019	80.3
<i>CM temphor</i>	913.2	17.3	0.225	80.0
<i>CM pres</i>	865.7	21.4	0.492	81.1
<i>CM superficie</i>	806.4	28.2	0.793	83.1
<i>CM tempreshum</i>	644.5	41.9	0.505	85.7
<i>CM Down</i>	504.6	43.7	0.024	86.5
<i>CM Down-viento</i>	426.1	47.1	0.765	87.5
<i>CM sondeos</i>	359.9	46.5	0.656	87.1
Modelo no causal	342.4	47.0	0.040	88.1

Tabla 3.21: Medidas de bondad de ajuste de las cadenas de Markov ajustadas en Zaragoza sobre el conjunto de validación (1998-2000).

Cabe destacar que *CM sondeos* reproduce mejor las rachas secas que los demás modelos, frente a los resultados en el periodo de estimación donde no destacaba. Con este modelo el valor mediano generado discrepa en más de un 30% del observado en cuatro meses, cuando lo hace en 8 meses con los restantes modelos. Respecto al rango intercuartílico, encontramos discrepancias de más de un 30% en dos meses con *CM superficie* y *CM sondeos*, mientras que los demás modelos las presentan en al menos cuatro meses.

Con las rachas secas del mes de Abril se encuentra un buen ejemplo de cómo los modelos que usan covariables de presión reproducen mejor este aspecto de la precipitación. La mediana observada es 5.5 días en el periodo 1990-1997 y 2 días en el 1998-2000. Los modelos *CM est* y *CM temp* generan para el periodo de validación valores semejantes al observado en el periodo de estimación (5.22 y 5.03 días, respectivamente), mientras que *CM superficie* y *CM sondeos*, con 2.95 y 2.35 días, aproximan mucho mejor el valor correcto. En el mes de Noviembre se produce una situación parecida.

Para las rachas húmedas, no se puede rechazar que la distribución simulada por los modelos corresponda con la observada. Hay discrepancias comunes; en el mes de Abril tanto la mediana, igual a 2 días, como el rango intercuartílico son subestimados por todos los modelos. Sin embargo, *CM superficie* y *CM sondeos* producen valores que distan menos de un 30% de la mediana observada en dos de los otros tres meses donde es superior a 1 día.

## 3.8 Conclusiones sobre la modelización de ocurrencia

En las secciones anteriores se han analizado individualmente los modelos de ocurrencia de cuatro localidades del Valle del Ebro, señalando los hechos más interesantes. En esta sección se realiza un análisis comparativo de esos modelos y se extraen algunas conclusiones. En la subsección 3.8.1 se comentan algunos aspectos relativos al proceso de modelización y en 3.8.2 se comparan los predictores obtenidos, el grado de ajuste de los modelos y la reproducción de las propiedades agregadas.

### 3.8.1 Conclusiones sobre el proceso de modelización

La estimación de las probabilidades de transición de una cadena de Markov mediante regresión logística es un método potente para construir modelos de ocurrencia, con el que es posible ajustarlos haciendo que la probabilidad de ocurrencia de lluvia dependa de una información atmosférica compleja.

Los modelos resultantes son interpretables, ya que la señal de ocurrencia queda expresada en términos de las covariables climáticas, la memoria del proceso y los armónicos presentes en el predictor lineal. El modelo se puede hacer más comprensible efectuando distintas parametrizaciones del predictor lineal, por ejemplo con la definición de las covariables *cambio.T* o *cambio.presion*, usadas en Zaragoza.

Otra ventaja de este procedimiento es la sencillez para analizar la significación de nuevos términos en el predictor. Los modelos obtenidos son susceptibles de mejora mediante la inclusión de información adicional. Ésta puede ser información disponible no utilizada, como las variables de viento en superficie a las horas-tipo o la adición de términos de interacción entre las covariables climáticas y los armónicos que permitieran modificar su efecto a lo largo del año; alternatively, puede incluirse nueva información en el modelo como datos del entorno espacial del observatorio o índices de teleconexión.

Unido a la posibilidad de utilizar mayor información, surge el inconveniente de la disminución del periodo de registro. A partir de una serie observada breve puede no obtenerse evidencia de la significación de algunos efectos que sí la tienen cuando se cuenta con un mayor tamaño muestral. En los modelos del mismo tipo de Reinosa, Agoncillo y Tortosa se ha requerido mayor orden de memoria que en el correspondiente a Zaragoza, a pesar de que la ocurrencia

cia de lluvia en este observatorio se asemeja a la de los dos últimos. Si se comparan los modelos del mismo tipo de Agoncillo y Zaragoza se observa que los de Agoncillo, donde se dispone de un periodo mayor de estimación, tienen predictores lineales más complejos. Martín-Vide y Gómez (1999) [87], que ajustan cadenas de Markov homogéneas a las series diarias con un periodo común de estimación, 1951-1990, encuentran que el orden en Zaragoza es 4, en Logroño y Santander (observatorio más próximo a Reinosa de los que analizan) es 3 y en Tortosa 2.

### 3.8.2 Comparación entre los resultados obtenidos

En este apartado se comparan los modelos del mismo tipo ajustados en cada observatorio, en los aspectos relativos a la composición del predictor lineal, el grado de ajuste alcanzado y la reproducción de las propiedades asociadas al ciclo anual, las transiciones a otro estado o la longitud de racha. En cada caso, se identifican los comportamientos similares y las diferencias, atendiendo a la posición y al clima de los observatorios.

#### Composición del predictor lineal

Para cada tipo de modelo, los cuatro observatorios muestran diferencias en el orden de memoria, en la estructura de armónicos o en los retardos significativos de las covariables climáticas; sin embargo, se encuentran también similitudes, por ejemplo en el signo y magnitud de algunos parámetros estimados. A continuación se señalan los aspectos más interesantes:

- En los modelos homogéneos el orden de memoria es 2 en Zaragoza, donde la longitud del periodo de estimación es 8 años, 4 en Agoncillo y Tortosa, con 15 y 40 años de observaciones, respectivamente, y 6 en Reinosa, con 48 años de periodo de estimación.
- En los predictores de los modelos *CM hom*, los coeficientes correspondientes a los dos primeros retardos toman valores similares en los cuatro observatorios, ver tabla 3.22. Los coeficientes estimados del indicador de ocurrencia en el día  $t - 3$ , en los tres observatorios en que es significativo, son también de un valor similar, de 0.22 a 0.28, y mayores que el correspondiente al día  $t - 4$ .
- En los cuatro predictores de *CM hom* existe un término de interacción entre los dos primeros retardos, cuyo efecto anula aproximadamente el del día  $t - 2$ . En todos los modelos ajustados en Reinosa, Tortosa y Agoncillo se mantiene ese término de interacción y su relación con el efecto de  $Y_{t-2}$ .

<i>CM hom</i>				
Efecto	Reinosa	Agoncillo	Zaragoza	Tortosa
$Y_{t-1}$	1.789 (0.050)	1.697 (0.087)	1.427 (0.127)	1.627 (0.060)
$Y_{t-2}$	0.368 (0.052)	0.490 (0.097)	0.533 (0.143)	0.360 (0.069)
$Y_{t-1} : Y_{t-2}$	-0.456 (0.072)	-0.706 (0.137)	-0.451 (0.218)	-0.412 (0.101)
<i>CM est</i>				
Efecto	Reinosa	Agoncillo	Zaragoza	Tortosa
$Y_{t-1}$	1.735 (0.051)	1.647 (0.088)	1.276 (0.107)	1.616 (0.060)
$Y_{t-2}$	0.230 (0.053)	0.435 (0.097)	0.277 (0.111)	0.339 (0.069)
$Y_{t-1} : Y_{t-2}$	-0.475 (0.073)	-0.708 (0.138)	–	-0.439 (0.102)

Tabla 3.22: Coeficientes estimados de los dos primeros retardos en los modelos *CM hom* y *CM est* en los cuatro observatorios. Entre paréntesis aparece el error estándar.

- En el modelo *CM est*, en todos los observatorios salvo en Zaragoza, el efecto relativo a los dos primeros retardos de la ocurrencia, señalado en el párrafo anterior, permanece; los coeficientes sufren pequeñas modificaciones, ver tabla 3.22. En Zaragoza desaparece esa interacción.
- La necesidad de incluir un orden de memoria 6 en *CM hom* y hasta 6 armónicos en *CM est* en Reinosa se explica por la dificultad de representar el ciclo anual en este observatorio. Tiene una estación seca de dos meses de duración, con una frecuencia de lluvia bastante menor que en el resto del año, mientras en el prolongado periodo no seco la frecuencia presenta ligeras oscilaciones, ver figura 3.2.
- La introducción de armónicos en *CM est* reduce la memoria en los observatorios con mayor frecuencia de lluvia, Reinosa y Agoncillo, y no la modifica en Zaragoza y Tortosa, ver tabla 3.23. Los dos primeros tienen un ciclo anual, ver figura 3.2, de mayor amplitud, y el modelo homogéneo requiere, para representar la fuerte reducción de su frecuencia en el Verano, un orden de memoria que no es necesario cuando se introducen los armónicos.
- En todos los modelos *CM temp* ajustados, el efecto lineal del rango de temperatura es el que tiene mayor valor del estadístico  $t$ . El valor del coeficiente es análogo en Tortosa y Zaragoza y algo menor en los observatorios más occidentales, ver figura 3.36. El rango del día previo, también significativo en todos los observatorios, tiene un coeficiente semejante en los tres observatorios de clima no atlántico y un menor impacto en el de Reinosa, ver figura 3.37.

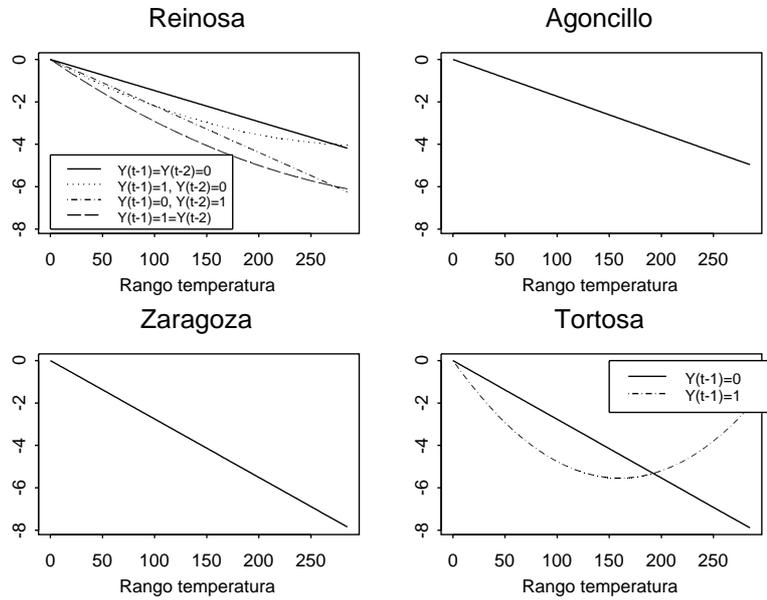


Figura 3.36: Efecto del rango de temperatura del día  $t$  en el modelo  $CM\ temp$  en los cuatro observatorios.

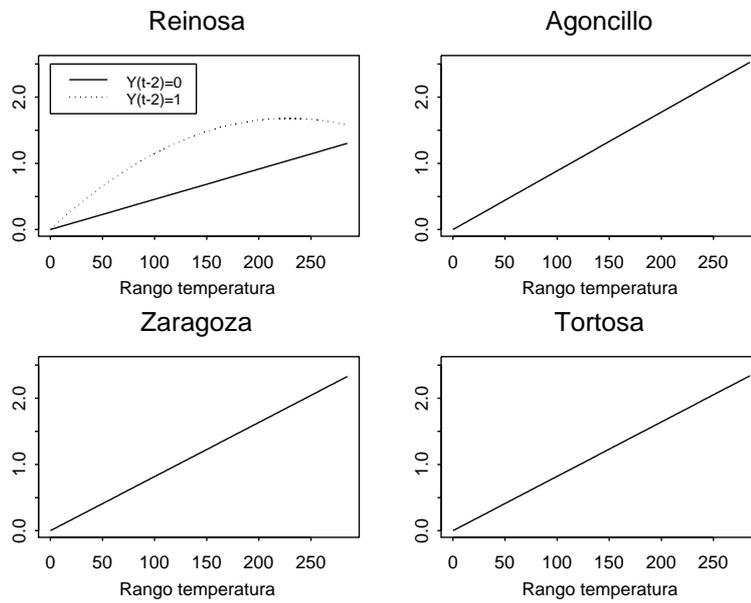


Figura 3.37: Efecto del rango de temperatura del día  $t - 1$  en el modelo  $CM\ temp$  en los cuatro observatorios.

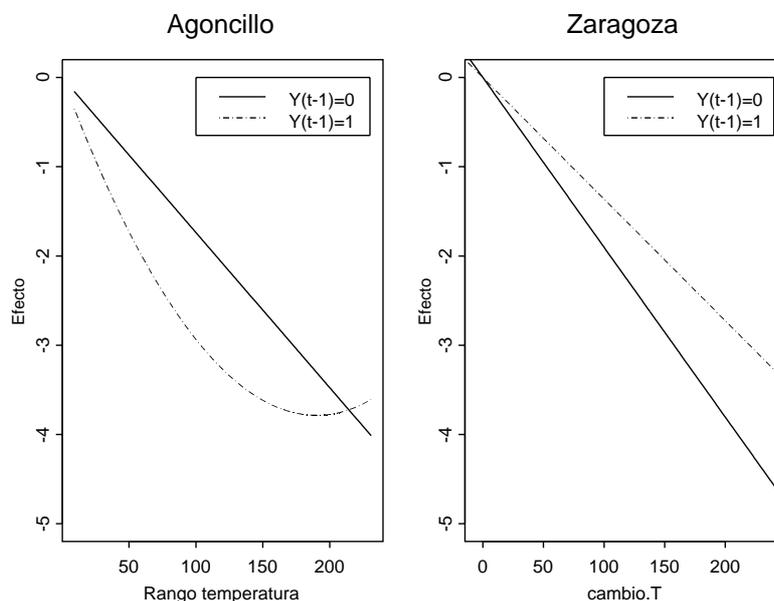


Figura 3.38: Efecto de la variable que representa la variación diaria de temperatura en los modelos con temperatura y presión de Agoncillo y Zaragoza.

- Los modelos con temperatura y presión en Agoncillo y Zaragoza presentan también características comunes:
  - Los coeficientes que acompañan a la variable que representa el cambio de temperatura en el día  $t$  indican el mismo tipo de relación negativa y toman valores semejantes, ver tablas A.35 y A.59 y figura 3.38. Su término lineal es el más significativo de todas las variables que intervienen. La interacción con la ocurrencia en el día previo modifica ese efecto en ambos modelos, de distinta forma.
  - El coeficiente que representa el efecto lineal de la presión a las 18 horas y su interacción con  $Y_{t-1}$  son del mismo signo y magnitud en ambos observatorios.
  - La influencia del cambio de la presión a lo largo del día se expresa de manera más simple en el modelo de Zaragoza; su efecto positivo es coherente con el asociado al cambio de presión entre las 13 y las 18 horas en Agoncillo.

### Bondad de ajuste

La tabla 3.23 muestra un resumen de las medidas de bondad de ajuste de los modelos analizados. Destacaremos algunos hechos:

Modelo	Observ.	Memoria	%var. exp.	% días bien clasificados					
				umbral 0.5		umbral frec. día		umbral frec. día	
				Global	$Y_t = 0$ $Y_{t-1}=1$	$Y_t = 1$ $Y_{t-1}=0$	Global	$Y_t = 0$ $Y_{t-1}=1$	$Y_t = 1$ $Y_{t-1}=0$
Homogéneo	Reinosa	6	16.8 (17.6)	70.3 (70.5)	0	0	64.3	0	9.6
	Agoncillo	4	12.0 (11.4)	72.2 (70.5)	20.1	0	63.4	0	13.5
	Zaragoza	2	7.7 (4.7)	77.3 (78.0)	100	0	63.7	0	14.1
	Tortosa	4	9.3 (12.2)	78.1 (77.6)	55.1	0	69.5	0	13.0
Estacional	Reinosa	3	18.6 (19.1)	70.6 (70.8)	10.2	0	70.3	0	0
	Agoncillo	3	13.3 (11.2)	72.9 (70.8)	33.2	0	70.9	0	5.0
	Zaragoza	2	8.5 (4.9)	77.3 (77.3)	100	0	72.8	0	6.6
	Tortosa	4	10.0 (12.9)	78.1 (77.6)	83.8	0	72.1	0	13.0
Temp. máxima y mínima	Reinosa	3	26.5 (28.5)	73.2 (74.0)	33.0	18.7	70.7	23.8	25.6
	Agoncillo	2	18.9 (17.1)	75.3 (73.6)	51.6	5.8	68.3	10.1	31.5
	Zaragoza	2	17.9 (14.4)	79.7 (80.3)	74.8	6.3	68.3	18.8	52.2
	Tortosa	4	18.8 (23.3)	81.1 (81.9)	80.1	4.9	70.8	13.7	41.1
Temp. y presión	Agoncillo	2	29.3 (32.0)	79.5 (78.9)	66.5	34.6	75.0	32.9	60.0
	Zaragoza	1	30.9 (28.2)	82.8 (83.1)	79.8	33.1	76.3	31.8	66.3
Sondeo	Zaragoza	1	49.0 (46.5)	86.9 (87.1)	83.0	53.7	82.5	58.0	79.4

Tabla 3.23: Medidas de bondad de ajuste de los modelos de ocurrencia ajustados en los cuatro observatorios; entre paréntesis, valores correspondientes al periodo de validación.

- La mejora en el grado de ajuste asociada a la inclusión de una covariable es similar en los cuatro observatorios, a pesar de las peculiaridades de la precipitación. La variabilidad explicada por *CM hom* la mejora, entre un 0.7 y un 1.8%, *CM est*. La de éste a su vez, se mejora entre un 5.6 y un 9.4% cuando se incluye información de temperatura; la presión y las variables del radiosondeo la incrementan alrededor de un 10% y un 20%, respectivamente.

La variabilidad explicada por el modelo causal más complejo ajustado en Zaragoza es comparable a los valores alcanzados por Beckmann y Buishand (2001) [20] en distintos observatorios europeos, entre un 40% y un 50%.

- Para cada tipo de modelo, el porcentaje de variabilidad explicada en los cuatro observatorios se ordena siguiendo el orden de la frecuencia de lluvia: Tortosa y Zaragoza se diferencian menos de un 2% en cualquiera de los modelos comparables. Agoncillo tiene mejores porcentajes que esos dos observatorios en los modelos sin covariables y porcentajes similares a los de Zaragoza en los modelos que incluyen temperatura. En el observatorio más húmedo, Reinoso, los modelos sin temperatura proporcionan porcentajes de variabilidad explicada que sólo se alcanzan en los otros observatorios introduciendo covariables climáticas. Los modelos sencillos caracterizan mejor la ocurrencia de lluvia en los observatorios donde ésta es más frecuente y estable a lo largo del año, que en aquéllos donde es más irregular.
- El porcentaje de días bien clasificados usando el umbral 0.5 se ve favorecido por la aridez del clima. Agoncillo tiene resultados peores que los alcanzados en Zaragoza y Tortosa. Reinoso, donde *CM temp* presenta el mayor porcentaje de variabilidad explicada, tiene el menor tanto por ciento de días bien clasificados.

La sensibilidad de esta medida para discriminar entre modelos es menor que la de la variabilidad explicada: ésta cambia del 7.7% al 49% en Zaragoza y del 16.8% al 26.5% en Reinoso, mientras el porcentaje de días bien clasificados se incrementa sólo en un 7.6% y en un 2.9%, respectivamente.

En cualquier caso, los porcentajes de días bien clasificados son de la misma magnitud o superiores al 75% obtenido por Klein Tank y Buishand (1995) [77] para el observatorio de De Bilt (Holanda), con un modelo de ocurrencia que utilizaba como predictores la temperatura y la presión.

- Un aspecto importante es la valoración de los modelos de acuerdo con su capacidad para caracterizar los cambios de racha. En este aspecto los modelos no son tan satisfactorios como en otros, aunque la inclusión de información mejora notablemente los resultados. Utilizando el umbral 0.5 cabe señalar:
  - Los días más difíciles de reproducir son los de inicio de racha húmeda. Ninguno de estos días, en ninguna de las localidades, es identificado por los modelos sin covariables climáticas. Se consiguen porcentajes de acierto pequeños al incluir la información de temperatura. Sólo los modelos con información del radiosondeo clasifican correctamente más del 50% de estos días.
  - El primer día de una racha seca resulta más difícil de identificar cuanto mayor es la frecuencia de lluvia en el observatorio. Reinosa y, en menor medida, Agoncillo presentan, en los tres modelos comunes, porcentajes de días iniciales de racha seca bien clasificados bastante inferiores a los de Zaragoza.
- La clasificación usando como umbral la frecuencia diaria de ocurrencia da lugar a porcentajes de acierto menores que el umbral 0.5 y, a diferencia de éste, no favorece a los observatorios más áridos. Las mayores discrepancias en la clasificación con los dos umbrales se encuentran en los modelos homogéneo y *CM temp* de Zaragoza y Tortosa. Las diferencias son menores en el modelo estacional y en los que usan presión. Evidentemente, al utilizar este umbral mejora el porcentaje de días iniciales de racha húmeda bien clasificados y empeora el correspondiente a los inicios de racha seca.

El uso de un umbral alternativo al valor 0.5 nos parece útil, aunque debe estudiarse mejor su definición. Es necesario valorar la opción de que el umbral se defina como el máximo de la frecuencia relativa diaria, quizás multiplicada por un factor mayor que uno, y del nivel 0.5, para aprovechar las cualidades de ambos umbrales.

- El porcentaje  $\%NAS$  global, usando ambos umbrales, ver tabla 3.24, mejora con la inclusión de información y penaliza a los observatorios más áridos. Cabe destacar que el modelo *CM sondeos* en Zaragoza proporciona un valor de esta medida que en Reinosa se alcanza sólo con las temperaturas máxima y mínima.

Al analizar su comportamiento por estaciones encontramos que:

- Para cada modelo y estación, salvo en Verano, los valores de %NAS en Reinosa son muy semejantes con los dos umbrales. Esto ocurre también con el modelo *CM sondeos* de Zaragoza. En el resto de modelos y localidades los valores de %NAS con el umbral 0.5 son siempre menores.
- En el Verano de Reinosa y Agoncillo la medida %NAS con el umbral 0.5 alcanza su valor máximo con el modelo homogéneo. Con la frecuencia relativa de lluvia el mayor porcentaje corresponde al modelo más completo.

Las medidas basadas en la comparación del valor medio de la frecuencia mensual observada y del obtenido a partir de los modelos, son de escaso interés, ver tabla 3.25. El coeficiente de correlación no discrimina la calidad de los ajustes, mientras que el coeficiente de eficiencia sólo distingue el modelo homogéneo de los demás. El porcentaje medio de error toma el menor valor, en el caso de los observatorios de Reinosa, Agoncillo y Tortosa, en los modelos más complejos y, en el de Zaragoza, en el modelo con temperatura y presión. Estas mismas medidas, basadas en las frecuencias anuales, tampoco han permitido identificar el mal comportamiento de los modelos. No obstante, interesa valorar la utilidad de su aplicación en el futuro, sobre grupos de datos clasificados de acuerdo con la situación de la lluvia pasada o según una variable climática, para identificar problemas en el modelo o sugerir modificaciones.

La obtención de buenos resultados en las medidas de bondad de ajuste no garantiza la adecuada representación de la distribución de la longitud de las rachas. Tras el análisis de las rachas generadas en los distintos observatorios con los modelos ajustados, cabe destacar:

- La valoración de esta propiedad debe hacerse en épocas del año con un comportamiento similar de la lluvia. Sin distinguir estaciones, la hipótesis de igualdad no se rechaza en los modelos homogéneos, para ambos tipos de racha, en Reinosa y Zaragoza, ni para las rachas secas, en Tortosa y Agoncillo. Sin embargo, si se divide la muestra por meses se detectan bastante discrepancias, ver tabla 3.26.
- Con el modelo estacional se acepta la igualdad de distribuciones, en todos los meses, en Tortosa y Agoncillo; en Reinosa sólo se rechaza la igualdad en el mes de Agosto para las rachas húmedas. Los modelos *CM hom* y *CM temp* en esos observatorios simulan rachas que no corresponden con las observadas en un mayor número de meses.

Modelo	Observatorio	Umbral 0.5					Umbral frecuencia diaria				
		Global	Primavera	Verano	Otoño	Invierno	Global	Primavera	Verano	Otoño	Invierno
Homogéneo	Reinosa	49.41	52.08	34.12	49.46	56.24	46.02	52.08	27.63	49.28	56.24
	Agoncillo	32.66	37.66	26.15	30.21	33.33	32.88	41.33	21.08	32.29	40.06
	Zaragoza	0	0	0	0	0	24.38	27.17	18.97	24.92	29.25
	Tortosa	0	0	0	0	0	27.24	32.05	18.6	29.04	32.15
Estacional	Reinosa	48.63	52.08	26.61	49.46	56.21	49.4	52.08	34.12	49.46	56.21
	Agoncillo	31.33	40.22	9	27.8	34.34	36.45	42.17	26.81	33.97	38.79
	Zaragoza	8.06	15.72	4.27	4.83	7.49	28.28	29.82	24.76	26.77	31.19
	Tortosa	8.5	14.34	1.07	6.27	9.08	29.07	33.24	20.84	29.44	32.28
Temp. máxima y mínima	Reinosa	51.78	56.5	28.07	53	58.53	51.31	56.01	35.31	53.97	56.84
	Agoncillo	33.99	41.53	17.97	33.19	34.24	38.49	43.86	26.99	39.6	41.17
	Zaragoza	22.86	22.45	9.45	27.93	25.81	33.18	30.49	25.58	36.39	38.03
	Tortosa	23.39	28.91	12.88	23.79	24.64	32.83	39.49	26.47	32.04	32.94
Temp. y pres.	Agoncillo	44.96	51.63	24.14	45.04	48.83	48.16	54.56	33.86	49.75	51.45
	Zaragoza	36.89	38.89	28.69	38.75	37.96	42.63	48.89	37.5	42.73	41.94
Sondeo	Zaragoza	52.43	58.45	46.73	57.74	46.11	52.55	56.35	43.65	54.87	54.42

Tabla 3.24: Porcentaje %NAS obtenido en distintos modelos ajustados en los cuatro observatorios.

Modelo	Observatorio	Coef. correl.	Coef. eficiencia	Índice acuerdo	% medio error
Homogéneo	Reinosa	1.00	0.76	0.90	4.57
	Agoncillo	1.00	0.66	0.83	5.78
	Zaragoza	1.00	0.51	0.71	6.16
	Tortosa	0.99	0.61	0.79	2.05
Estacional	Reinosa	1.00	1.00	1.00	0.05
	Agoncillo	0.98	0.96	0.99	0.31
	Zaragoza	0.92	0.85	0.95	2.07
	Tortosa	0.99	0.98	0.99	0.13
Temp. máxima y mínima	Reinosa	1.00	1.00	1.00	0.08
	Agoncillo	0.98	0.96	0.99	0.28
	Zaragoza	0.85	0.72	0.92	2.16
	Tortosa	1.00	0.99	1.00	0.01
Temp. y presión	Agoncillo	0.98	0.95	0.99	0.23
	Zaragoza	0.92	0.83	0.96	0.85
Sondeo	Zaragoza	0.96	0.90	0.97	1.92

Tabla 3.25: Medidas de bondad de ajuste basadas en la frecuencia de días con precipitación, por meses, para los modelos ajustados en los cuatro observatorios.

- El menor tamaño muestral en los periodos de validación impide, en ciertos casos, disponer de la evidencia suficiente para rechazar la hipótesis de igualdad, a pesar de las importantes discrepancias detectadas entre los percentiles observados y estimados.

Notemos que los modelos obtenidos captan de forma adecuada las relaciones estables entre la ocurrencia de precipitación y las covariables climáticas, como se aprecia en la tabla 3.23, donde aparecen, entre paréntesis, los porcentajes que expresan la calidad del ajuste en los datos de validación.

- En los dos observatorios con mayor cantidad de datos, Reinosa y Tortosa, el porcentaje de variabilidad explicada no es menor en el conjunto de validación que en el de estimación y en los de Zaragoza y Agoncillo se observa una ligera reducción. Esas variaciones no están asociadas al uso de covariables concretas.
- El porcentaje de días bien clasificados usando el umbral 0.5 se modifica muy poco respecto al obtenido en el periodo de estimación.

Modelo	Observatorio	Racha seca	Racha húmeda
Homogéneo	Reinosa	7, 8	1, 6, 7, 8, 10, 11, 12
	Agoncillo	3	8, 11
	Zaragoza	–	1, 12
	Tortosa	7	8, 12
Estacional	Reinosa	–	8
	Agoncillo	–	–
	Zaragoza	–	–
	Tortosa	–	–
Temp. máxima y mínima	Reinosa	6, 8	4, 5, 6, 7, 9, 10
	Agoncillo	1	2, 7, 9
	Zaragoza	–	–
	Tortosa	9	3
Temp. y presión	Agoncillo	–	–
	Zaragoza	–	–
Sondeo	Zaragoza	–	–

Tabla 3.26: Meses en los que se rechaza al 5% la igualdad de distribución de la longitud de racha observada y la obtenida a partir de los modelos ajustados en los cuatro observatorios.

### Valoración final

El análisis de los modelos ajustados permite establecer las siguientes conclusiones generales:

1. Las cadenas de Markov homogénea y estacional son insuficientes para representar el proceso de la ocurrencia de lluvia, fundamentalmente por dos motivos: (a) porque reproducen peor la variabilidad interanual de la frecuencia de lluvia y (b) porque no consiguen caracterizar las transiciones del estado seco al húmedo, a las que asocian probabilidades muy bajas.
2. La inclusión progresiva de covariables climáticas permite mejoras muy importantes en los modelos. Utilizando únicamente las temperaturas máxima y mínima diarias en superficie, el rango se revela como una variable fuertemente relacionada con la precipitación. El modelo con la información del radiosondeo proporciona probabilidades ajustadas que clasifican correctamente más de la mitad de los días iniciales de racha.
3. El orden de memoria de las cadenas se reduce, en buena parte, con la inclusión de covariables climáticas.

Frente a la posibilidad de construir modelos diferentes para cada una de las estaciones del año, que reflejaran el distinto comportamiento de la lluvia, se ha optado por establecer modelos más simples en los que el efecto de cada covariable climática fuese el mismo en cualquier época. Esto puede dificultar el reconocimiento de la significación de algunos efectos, por ejemplo en Verano; sin embargo, los problemas para caracterizar la lluvia en esta estación se han superado en el modelo con información de la troposfera, en el que se alcanza un grado de ajuste satisfactorio sin necesidad de construir un modelo particular.

Señalemos, finalmente, la necesidad de definir una variedad de controles sobre la calidad del ajuste de los modelos. Esto es particularmente necesario en aquéllos que vayan a ser utilizados para la simulación de secuencias diarias de precipitación para usos hidrológicos, ligados a la producción agrícola o para la valoración del cambio climático. Resulta indispensable analizar criterios referidos a la reproducción del ciclo anual de la precipitación pero es igualmente necesario valorar si la sucesión de días húmedos y secos generada por el modelo se comporta de manera semejante a la observada, tanto en la persistencia del estado como en las transiciones entre ellos.

## 3.9 Modelos para la cantidad de precipitación diaria

Modelada ya la ocurrencia, para completar el modelo de precipitación diaria que estamos construyendo es necesario seleccionar una distribución de probabilidad para la cantidad de lluvia, identificar su estructura de dependencia y analizar su relación con otras covariables.

En la subsección 3.9.1 se revisan algunos antecedentes sobre los modelos de cantidad, en la 3.9.2 se presenta el modelo y su procedimiento de estimación y en la 3.9.3 las herramientas que se utilizarán para valorar los modelos ajustados.

### 3.9.1 Distribución e hipótesis de independencia

En la definición de un modelo de cantidad de lluvia existen dos cuestiones iniciales importantes: identificar el grado de dependencia entre las observaciones sucesivas y seleccionar la distribución, continua y asimétrica, que utilizaremos para representarla. Hemos desarrollado algunos trabajos sobre este tema en los que, en distintas condiciones, estudiamos los ajustes que proporcionaban algunas distribuciones, como la de Weibull y Gamma, así como la necesidad de construir modelos condicionales como alternativa a los que consideran las observaciones independientes.

En Abaurrea y otros (1995) [2] se ajustó un modelo con error Weibull para la cantidad de lluvia en el observatorio del aeropuerto de Zaragoza, en el que la media se expresaba en función del comportamiento estacional y contenía información relativa a la precipitación en los días cercanos. Aunque la distribución de Weibull no pertenece a la familia exponencial y el modelo no es estrictamente un GLM, se utilizó el software GLIM4 para hacer estimaciones máximo-verosímiles de los parámetros del predictor.

En Abaurrea y Asín (1997) [4] se consideró el problema de la selección de una distribución adecuada para la cantidad de precipitación diaria en los observatorios de Reinoso y Tortosa. A partir de un análisis exploratorio se seleccionó la distribución más conveniente dentro de un conjunto que contenía los modelos Weibull, Lognormal, Gamma y Log-logístico, entre otros. Por razones de homogeneidad, las observaciones se agruparon por estaciones y tomando en cuenta la ocurrencia de lluvia en el día precedente. Los resultados de ese análisis indicaron que la distribución de Weibull y el modelo Gamma eran los más adecuados.

Los modelos que se presentan consideran que las observaciones de precipitación en los días con lluvia constituyen una sucesión de variables aleatorias con distribución Gamma. En la revisión bibliográfica hecha en el primer capítulo se han señalado varios trabajos en los que el modelo Gamma ha sido usado como distribución de la cantidad: Stern y Coe (1984) [108], Wilby (1994) [115], Buishand y Klein Tank (1996) [24], Wilby y otros (1998) [117].

Como esta distribución pertenece a la familia exponencial, el modelo propuesto constituiría un GLM si los datos fueran independientes. En los modelos ajustados consideraremos que el parámetro de dispersión es constante y que en el valor medio de la distribución influyen distintas covariables; el objetivo es captar, con pocos parámetros, el carácter estacional y la dependencia de la situación atmosférica de la cantidad de lluvia recogida.

Otros autores han modelado también la dependencia de la cantidad de precipitación de la situación climática: Goodess (2000) [50] define una distribución para cada tipo de clima o estado atmosférico de la clasificación que utiliza y Beckmann y Buishand (2001) [20] ajustan un modelo aditivo generalizado que incluye covariables como la presión o humedad.

En relación con el tema de la independencia de las observaciones sucesivas, Buishand (1977) [23] ya detectó en diversos observatorios de los Países Bajos la existencia de interacción entre el modelo de ocurrencia y el de cantidad, encontrando una correlación pequeña, pero significativa, entre las cantidades recogidas en días lluviosos consecutivos. En Smith (1994) [107] se propone un modelo de cantidad diaria en el que ésta queda condicionada por los indicadores de ocurrencia y las cantidades registradas en los días previos. Con ayuda del criterio AIC se determina el número de retardos que deben incluirse en el modelo. El autor encuentra que son necesarios dos retardos en muchos observatorios de Carolina del Norte y que, en alguno de ellos, el ajuste del modelo mejora con la inclusión de la cantidad registrada en días anteriores.

Atendiendo a esta posibilidad no hemos hecho la hipótesis de independencia, sino que se plantea la conveniencia de incluir el efecto de la cantidad o la ocurrencia observada en días anteriores. En los cuatro observatorios analizados se ha encontrado esa dependencia.

### 3.9.2 Estimación de los modelos Gamma

El modelo para la cantidad de precipitación diaria es una extensión de tipo condicional de un GLM, ya que considera que la cantidad esperada está condicionada por la lluvia observada en los días previos. Las variables predictoras van a ser las utilizadas en los modelos de ocurrencia y, además, los indicadores de lluvia y las cantidades registradas en los días anteriores.

La función de enlace canónica para un GLM con error Gamma es la recíproca. Como este enlace no asegura el carácter positivo del valor ajustado, se ha seleccionado un enlace logarítmico.

La distribución Gamma está caracterizada por dos parámetros, uno de localización,  $\mu$ , y otro de dispersión,  $\nu$ . La función de densidad es:

$$f_Y(y) = \left(\frac{1}{\nu\mu}\right)^{\frac{1}{\nu}} \frac{y^{\frac{1}{\nu}-1} \exp\left(\frac{-y}{\nu\mu}\right)}{\Gamma\left(\frac{1}{\nu}\right)} \quad y \in (0, \infty)$$

La expresión que muestra el estadístico suficiente para el parámetro  $\mu$  permite identificar la estructura correspondiente a una densidad de la familia exponencial:

$$f_Y(y) = \exp\left(\frac{-\frac{y}{\mu} - \log(\mu)}{\nu}\right) \exp\left(-\frac{\log(\nu)}{\nu} + \left(\frac{1}{\nu} - 1\right) \log(y) - \log\left(\Gamma\left(\frac{1}{\nu}\right)\right)\right)$$

La esperanza y la varianza de la distribución Gamma son:

$$E[Y] = \mu \quad \text{Var}(Y) = \mu^2 \nu$$

por lo que una propiedad característica de la distribución es que el coeficiente de variación no depende del valor esperado:

$$\text{Coeficiente de variación} = \frac{\sqrt{\text{Var}(Y)}}{E[Y]} = \sqrt{\nu}$$

El inverso del parámetro de dispersión,  $\alpha = 1/\nu$ , se denomina parámetro de forma. Cuando  $\nu = 1$  la distribución Gamma se reduce a la Exponencial, para valores  $\nu < 1$  la distribución presenta una moda en  $\mu(1 - \nu)$  y si  $\nu > 1$  no existe moda y se produce una fuerte concentración en los valores próximos a 0.

En la construcción de los modelos se sigue el procedimiento utilizado en las cadenas de Markov de ocurrencia, ver subsección 3.3.1. La diferencia más

importante ahora es que el parámetro de dispersión no es conocido, por lo que la comparación de modelos se efectúa mediante un contraste F, que sustituye al test  $\chi^2$  utilizado en la regresión logística. El estadístico de contraste se define como el cociente de la diferencia entre las desviaciones y un estimador de la escala, obtenido al dividir la deviance del modelo más complejo por sus grados de libertad. Este estadístico se distribuye asintóticamente según una ley F, cuyos grados de libertad son los asociados a la diferencia entre el número de parámetros de los dos modelos y los grados de libertad residuales en el modelo complejo.

El estimador máximo-verosímil del parámetro de dispersión es poco robusto, por lo que teniendo en cuenta la recomendación de McCullagh y Nelder (1989) [89], se utiliza la estimación de momentos dada por el cociente de la suma de los cuadrados de los residuos de Pearson entre los grados de libertad residuales:

$$\hat{\nu} = \frac{1}{T-p} \sum_{t=1}^T \frac{(y_t - \hat{\mu}_t)^2}{\hat{\mu}_t^2}$$

### 3.9.3 Métodos para la evaluación de los modelos

En el estudio de Pierce y Schafer (1986) [95] que analiza los residuos más apropiados para validar un GLM, se señalan los residuos de la desviación como los más adecuados por su comportamiento aproximadamente normal, en particular en los GLM con error Gamma. La expresión de estos residuos es:

$$r_t^D = \text{sign}(y_t - \hat{\mu}_t) \frac{2}{\nu} \left( \log \left( \frac{\hat{\mu}_t}{y_t} + \frac{y_t - \hat{\mu}_t}{\hat{\mu}_t} \right) \right)$$

Para cada modelo se han construido gráficos de los residuos frente a los valores ajustados, frente al tiempo y a las covariables climáticas. La adecuación de su distribución al modelo Normal se valora mediante un histograma, un qq-plot y utilizando un contraste KS. El análisis de la autocorrelación residual nos permite decidir sobre el interés de incluir en el modelo valores retardados de la respuesta.

Para cada modelo estimado se presenta, en el anexo A, una tabla con sus medidas de bondad de ajuste que permiten compararlo con otros. La tabla incluye los valores de la deviance, el AIC, el BIC, los grados de libertad residuales y el porcentaje de variabilidad explicada, tanto global como por estaciones.

La crítica del modelo debe incluir un análisis de su capacidad para re-

producir el ciclo anual de la lluvia recogida y su comportamiento interanual. Con este objetivo se utilizan las medidas introducidas en los modelos de ocurrencia, coeficientes de correlación y eficiencia, índice de acuerdo y porcentaje medio de error, que se aplican a las cantidades agregadas mensual y anualmente.

A partir de la distribución ajustada para cada día, clasificamos la cantidad de lluvia observada en uno de los intervalos definidos por los dos deciles extremos y los cuartiles primero y tercero. Si el ajuste es adecuado, la frecuencia observada en los 5 intervalos así definidos debe estar próxima de la esperada. La discrepancia en esas frecuencias permite identificar aspectos defectuosos de la modelización.

Para valorar la capacidad del modelo para reproducir series semejantes a las observadas se han realizado 20 simulaciones de cada modelo ajustado usando las covariables asociadas a los días con precipitación positiva. Con los datos simulados se calculan las distribuciones mensuales, que se contrastan con las observadas; en cada mes se comparan la mediana, como medida de posición central, el rango intercuartílico, como medida de variabilidad, y el percentil 95, como valor a partir del cual se puede considerar que las cantidades toman valores extraordinarios; además, se realizan un test de Wilcoxon y un test KS para comparar las distribuciones.

Este procedimiento de crítica se lleva a cabo también en el conjunto reservado para la validación del modelo.

## 3.10 Modelos de cantidad ajustados

En esta sección se presentan los modelos que proporcionan el mejor ajuste en cada uno de los observatorios, utilizando la información disponible. En Zaragoza se incluye, además, un modelo con información de temperatura, presión y humedad en superficie, con el fin de compararlo con el modelo que incorpora información de la troposfera y del viento en superficie. En cada observatorio se han seleccionado los mismos periodos de estimación y validación que en los modelos de ocurrencia. La definición de día húmedo utilizada implica que la cantidad de lluvia observada sea igual o superior a una décima de litro.

Esta sección se estructura en cinco subsecciones; en las cuatro primeras se presentan los modelos de los observatorios estudiados y en la 3.10.5 se establecen algunas conclusiones sobre el proceso de modelización propuesto y sus resultados.

### 3.10.1 Modelo de cantidad en Reinosa

En primer lugar se analizó un modelo constituido por variables aleatorias independientes que prescindía de los retardos de la respuesta y que contenía la información relativa a las covariables climáticas y los armónicos. Los residuos de ese modelo presentaban una autocorrelación de orden 1, significativa, igual a 0.19. En el modelo que incorporaba, además, el indicador de ocurrencia en los dos días previos se obtuvo una autocorrelación residual de orden 1 igual a 0.18, también significativa.

El modelo finalmente seleccionado se muestra en la tabla A.84, donde se indican los coeficientes de los términos incluidos, su error estándar, el estadístico  $t$  y el valor del parámetro de dispersión. La influencia de la lluvia pasada aparece a través de los indicadores de ocurrencia de los dos días previos y de una expresión no lineal en la cantidad de lluvia del día  $t - 1$ . El coeficiente de  $Y_{t-1}$  indica que en el segundo día de una racha húmeda la cantidad esperada se incrementa en un 60% respecto del nivel base del primer día de lluvia ( $\exp(\beta_{Y_{t-1}=1}) = e^{0.477} = 1.61$ ). El efecto de la ocurrencia en el día  $t - 2$  supone un incremento del 13% y existe una interacción con  $Y_{t-1}$  que anula ese efecto.

En la figura 3.39 se muestra el efecto positivo que tiene la cantidad de lluvia en el día anterior: una cantidad de 1 litro tiene un impacto en el predictor lineal de 0.0692, lo que representa en el valor esperado un factor

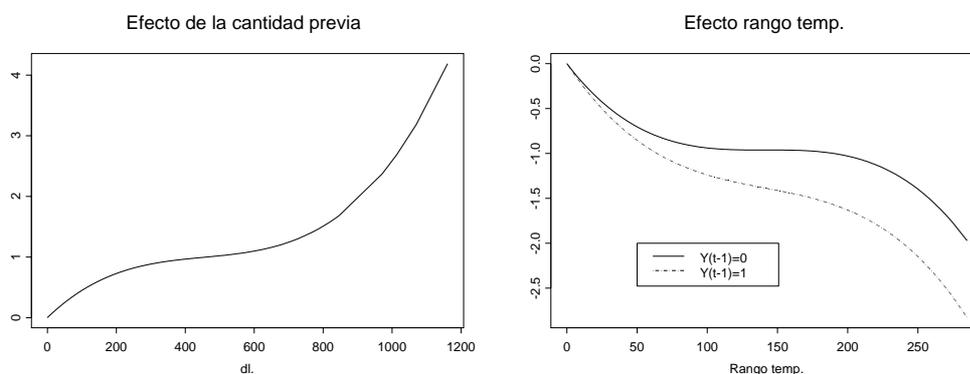


Figura 3.39: Izda.: Efecto de la cantidad del día previo en el modelo de cantidad en Reinosa. Dcha.: Idem del rango de temperatura en el día  $t$ .

1.07; 20 litros tienen asociado un factor 1.18.

La temperatura mínima y el rango de temperatura intervienen en el modelo con expresiones complicadas que incluyen términos cúbicos e interacciones con la memoria de lluvia. En la parte derecha de la figura 3.39 se representa el efecto negativo del rango diario de temperatura, que se acentúa cuando en el día previo se ha producido precipitación.

La tabla A.85 contiene algunas medidas que expresan el grado de ajuste del modelo. La autocorrelación de orden 1 de los residuos, no significativa, indica que se ha modelado la dependencia entre observaciones positivas consecutivas, que tenían un coeficiente de correlación 0.317. Por otra parte, destaca la escasa variabilidad explicada en las distintas estaciones, en particular en el Verano.

El resultado de la clasificación de las respuestas en los intervalos definidos por los percentiles seleccionados muestra que el modelo tiene problemas con las cantidades pequeñas. Sólo un 1% de las cantidades observadas se encuentran por debajo del percentil 10 de la distribución ajustada, lo que está provocado porque la mayor parte de las distribuciones ajustadas tienen percentiles  $q_{0,10}$  menores que 1 dl, ver figura 3.40. El porcentaje de observaciones clasificadas en el otro extremo de la distribución es del 9%.

En la figura 3.41 se muestran los histogramas y qq-plots de los residuos de la deviance para los subgrupos definidos por la ocurrencia de lluvia en el día previo. Se aprecia que la cola izquierda de la distribución no se comporta como una distribución gaussiana; por el contrario, los residuos positivos se

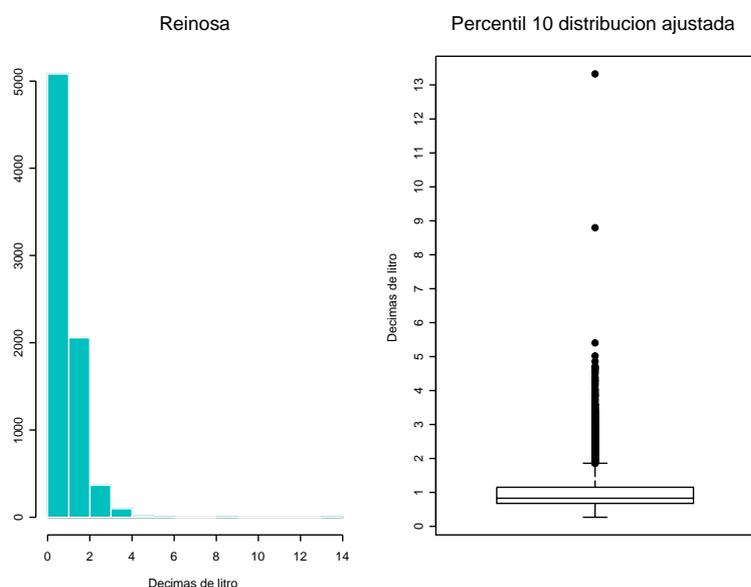


Figura 3.40: Histograma y diagrama de caja del percentil 10 de la distribuciones de cantidad ajustadas en Reinosa (1912-1959).

encuentran alineados sobre la recta identidad.

El modelo reproduce de forma correcta el comportamiento estacional de la cantidad de lluvia, ver figura 3.42, observándose sólo una discrepancia significativa en el mes de Agosto. En la figura 3.43, que contiene los diagramas de dispersión de las cantidades medias observadas y ajustadas según distintas agrupaciones, los diagramas superiores confirman la buena caracterización del ciclo estacional por parte del modelo. Los diagramas inferiores, que tienen asociados coeficientes de correlación de 0.77 y 0.78, indican que los valores medios ajustados captan el carácter húmedo o seco del periodo, año o mes, pero no siguen la relación identidad.

El modelo ajustado se ha simulado 20 veces utilizando los valores observados de las covariables. En la tabla A.86 se presentan algunas características de las cantidades simuladas y observadas, expresadas en decilitros. Los valores medianos son similares; sólo en Agosto y en Septiembre se producen discrepancias superiores al 30% del valor observado. La mayor diferencia en el percentil 95, 6 litros, se observa en el mes de Julio y representa una desviación de un 24%. A pesar de la similitud aparente, el test KS rechaza en todos los meses la hipótesis de igualdad, mientras que el test de Wilcoxon es significativo en Octubre y desde Diciembre hasta Abril.

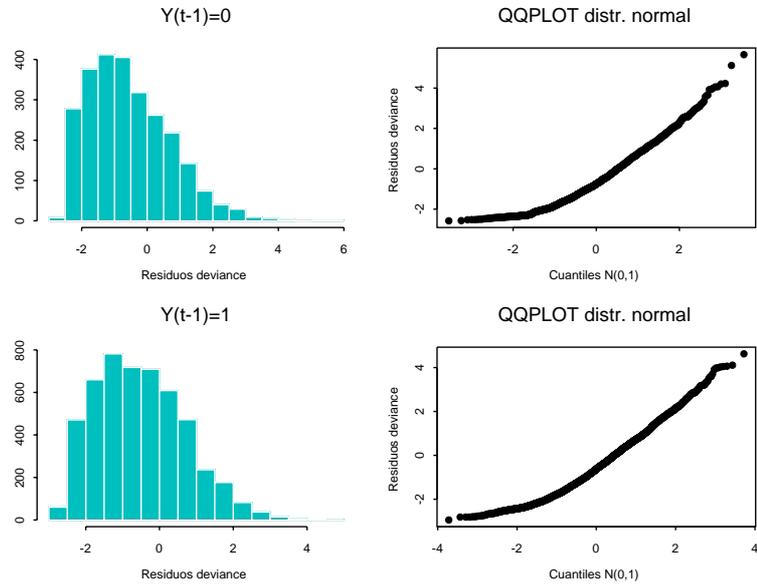


Figura 3.41: Histograma y qq-plot de los residuos del modelo de cantidad en Reinosa (1912-1959), según la ocurrencia de lluvia en el día previo.

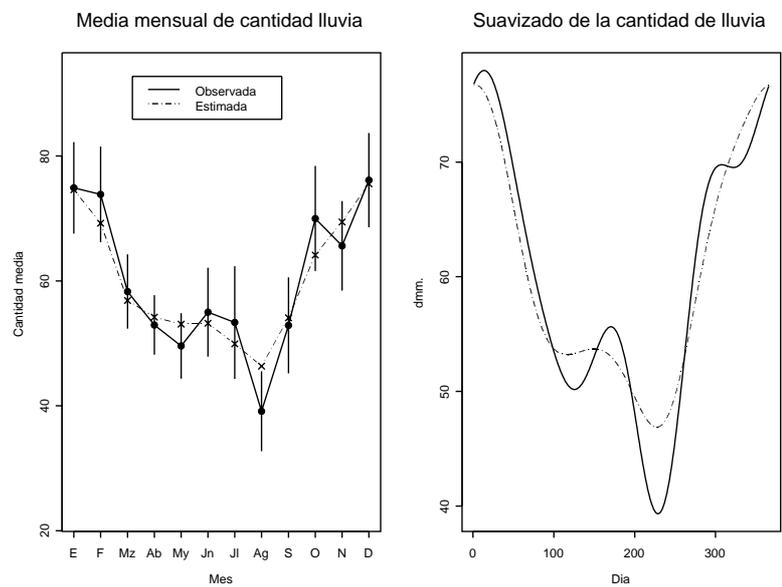


Figura 3.42: Izda.: Cantidad media observada y ajustada, por meses, Reinosa (1912-1959). Dcha.: Suavizado de los valores diarios observados y ajustados.

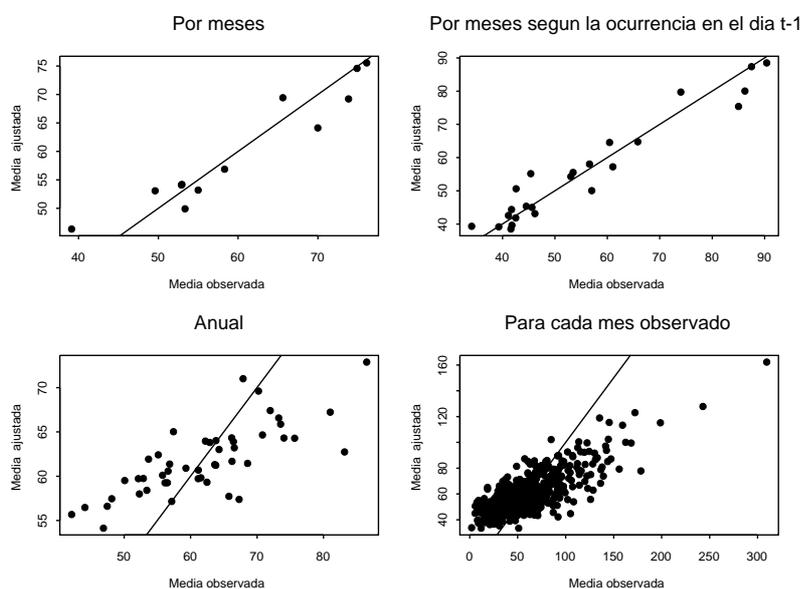


Figura 3.43: Diagramas de dispersión de las cantidades medias ajustadas vs. observadas en Reinosa (1912-1959), por meses, por meses y según la ocurrencia en el día previo, por años, por meses y años.

### Comportamiento del modelo en el periodo de validación

En la tabla A.87 se presentan las medidas de bondad de ajuste del modelo en el periodo de validación. La variabilidad explicada es un 7.2%, la mitad de la alcanzada en el periodo de estimación. Como ocurría en aquel periodo, el ajuste del Verano es insuficiente pero lo más destacable es la reducción de variabilidad explicada observada en Invierno, donde se pasa de un 21% a un 6%. El perfil estacional se representa correctamente, hay un coeficiente de correlación 0.84 entre las medias mensuales observadas y ajustadas y, como en el periodo de estimación, el modelo no consigue reproducir la variabilidad interanual.

La clasificación de las observaciones en los intervalos definidos por los percentiles de la distribución ajustada es muy semejante a la vista en la tabla A.85. En cada clase se clasifica una proporción similar a la esperada, salvo en la de los valores pequeños y en la contigua a ésta debido a los problemas de aquélla.

La autocorrelación de orden 1 de los residuos indica, de nuevo, que la dependencia entre observaciones ha sido captada adecuadamente.

La tabla A.88 contiene una descripción de las cantidades simuladas y observadas en los días con cantidad positiva. El test KS rechaza la igualdad de las distribuciones simulada y observada, salvo en los meses de Junio, Julio y Agosto, aunque en Julio se produce una discrepancia importante en los percentiles  $q_{0.50}$  y  $q_{0.95}$ . En el resto de los meses, sólo la mediana del mes de Enero y el percentil 95 de Abril tienen una discrepancia superior al 30% del valor observado.

De los comentarios anteriores se deduce que el modelo de cantidad es claramente insuficiente. Se puede considerar que ha recogido adecuadamente la dependencia entre las observaciones consecutivas, el comportamiento estacional y la caracterización de las cantidades mayores, pero se identifican problemas en la reproducción de la variabilidad interanual y en el ajuste de las cantidades pequeñas de lluvia.

### 3.10.2 Modelo de cantidad en Tortosa

El periodo utilizado para la estimación del modelo en Tortosa comprende los años 1942 a 1981 y el reservado para la validación, el intervalo 1982-1991.

Como en el caso de Reinoso se requiere que el modelo sea de tipo condicional. El primer modelo considerado, que supone independencia y utiliza información de temperatura, tiene una autocorrelación residual de orden 1, significativa, igual a 0.12. Un segundo modelo, que añade al anterior los indicadores de ocurrencia de la lluvia pasada y que explica un 15.5% de la variabilidad de la respuesta y reproduce correctamente el comportamiento estacional, ver figura 3.44, tiene una autocorrelación residual de orden 1 igual a 0.11, significativa al 5%.

El predictor lineal del modelo seleccionado es relativamente simple, ver tabla A.89. La influencia de la cantidad de lluvia en el día previo se puede valorar considerando que, por ejemplo, una cantidad de 10 litros implica un incremento en el valor esperado de factor 1.276. El rango de temperatura es la covariable con mayor estadístico  $t$  y aparecen también en el modelo las temperaturas mínimas en el día  $t$  y en el  $t - 1$ , con un efecto de signo contrario.

El coeficiente de dispersión del modelo ajustado es 2.83. La figura 3.45 muestra la función de densidad de una distribución Gamma con ese parámetro de dispersión y la de una distribución Exponencial, ambas con valor esperado igual a la media de las cantidades observadas. En la figura aparece

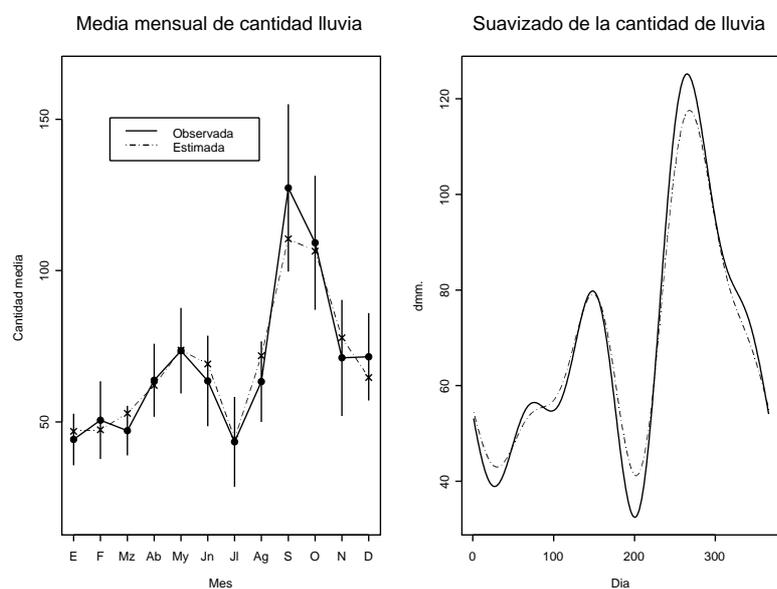


Figura 3.44: Izda.: Cantidad media observada y ajustada, por meses, con el modelo de cantidad que no incluye  $Q_{t-1}$ , Tortosa (1942-1981). Dcha.: Suavizado de los valores diarios observados y ajustados.

también el cociente entre ambas funciones, lo que permite valorar su distinto comportamiento: la distribución Gamma presenta mayor concentración en los valores cercanos a 0 y en la cola derecha, donde asigna mayor probabilidad a los intervalos situados a la derecha del umbral 21.5 litros.

La tabla A.90 incluye las medidas de bondad de ajuste de este modelo, cuyo porcentaje de variabilidad explicada es de un 6% en el Verano y alrededor de un 16% en el resto de las estaciones. El modelo capta la dependencia entre las observaciones sucesivas, ya que la autocorrelación residual de orden 1, 0.03, no es significativa al 5%.

El modelo reproduce adecuadamente el ciclo anual de la variable. En la figura 3.46 no se aprecian discrepancias significativas entre los valores medios de las cantidades observadas y ajustadas, aunque en Septiembre existe una ligera subestimación. En la tabla 3.27 se muestra la similitud entre los valores medios de las cantidades acumuladas estacionales observadas y ajustadas. Esto no ocurre cuando se comparan los valores medios anuales, ver diagrama inferior izquierdo de la figura 3.47, cuyo coeficiente de correlación es sólo de 0.55, valor menor que el alcanzado en Reinosa en el periodo de validación. El coeficiente de correlación cuando se comparan los valores medios de cada

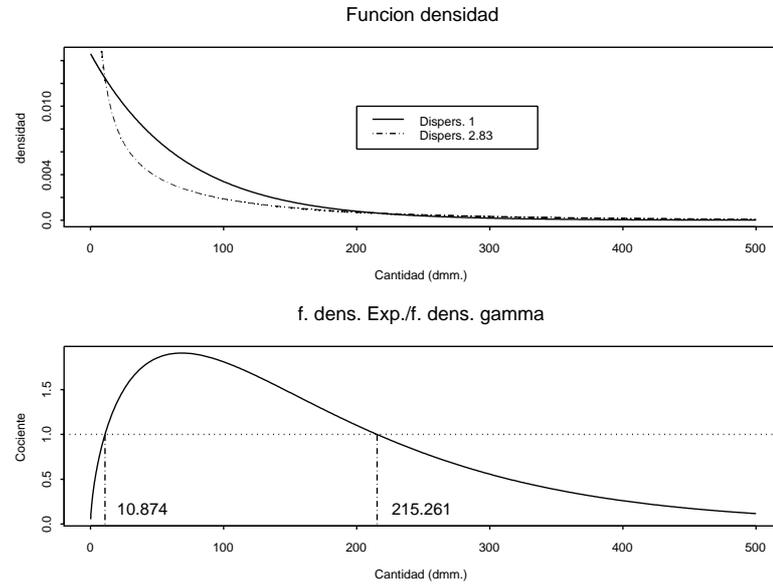


Figura 3.45: Sup.: Funciones de densidad Exponencial y Gamma ( $\nu = 2.83$ ) con valor medio igual al observado. Inf.: Cociente entre ambas funciones.

mes observado es 0.65.

Un aspecto destacable aparece al analizar los percentiles de los residuos, expresados en décimas de litro, de la tabla 3.27. En Otoño las discrepancias son mayores que en el resto de las estaciones debido a las situaciones de depresión aislada en niveles altos de la atmósfera, que dan lugar al fenómeno denominado de ‘gota fría’, que produce intensas precipitaciones. El modelo de cantidad ajustado no contiene la información necesaria para caracterizar estas situaciones.

La clasificación de las observaciones en los intervalos definidos por los deciles y cuartiles de las distribuciones ajustadas coloca por encima del percentil 90 algo menos del 10% de los datos. Como en Reinos, el modelo no proporciona distribuciones cuyo percentil 10 sea mayor que 1 décima de litro, ver figura 3.48.

Las 20 simulaciones realizadas del modelo dan lugar a distribuciones mensuales que se comparan con las observadas en la tabla A.91. El contraste KS indica que las distribuciones que proporciona el modelo no se corresponden con las observadas en ninguno de los meses. La mediana obtenida es un 30% menor que el valor observado en los meses de Enero, Febrero y Marzo y un

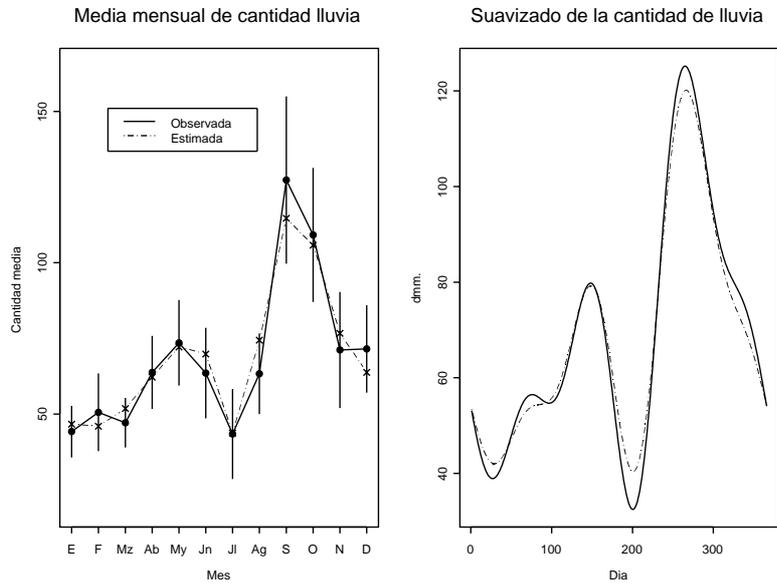


Figura 3.46: Izda.: Cantidad media observada y ajustada, por meses, con el modelo de cantidad, Tortosa (1942-1981). Dcha.: Suavizado de los valores diarios observados y ajustados.

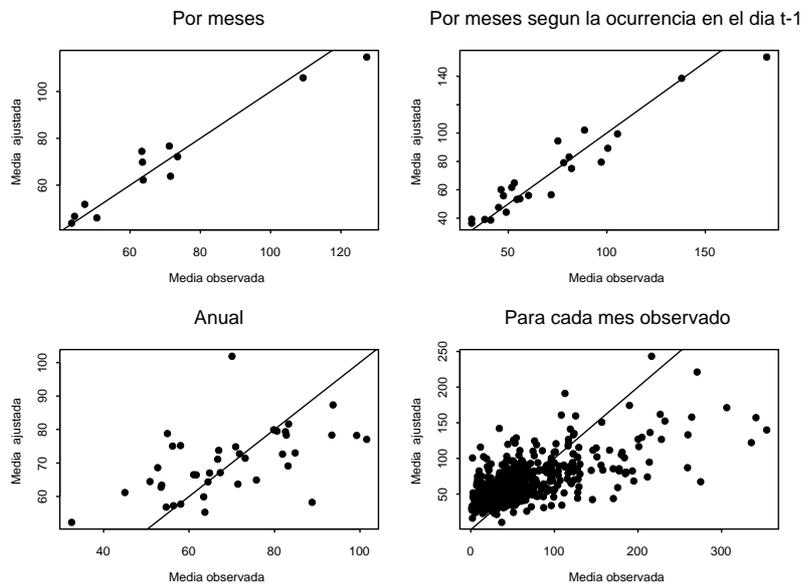


Figura 3.47: Diagramas de dispersión de las cantidades medias ajustadas vs. observadas en Tortosa (1942-1981).

Estación	Primavera	Verano	Otoño	Invierno
Media observada	1454.36	940.13	2058.3	1150.93
Media ajustada	1465.98	1042.93	1978.96	1079.81
Percentiles de los residuos por estaciones				
$q_{0.05}$	-83.13	-102.01	-162.87	-73.2
$q_{0.25}$	-42.09	-50.1	-74.03	-37.61
$q_{0.50}$	-22.83	-30.54	-41.58	-21.48
$q_{0.75}$	5.82	1.3	9.11	4.68
$q_{0.90}$	88.23	96.32	175.94	92.19
$q_{0.95}$	179.35	156.36	359.51	181.66
$q_{0.99}$	429.98	490.53	750.04	419.77
$q_{0.995}$	489.61	594.61	830.93	514.19
Máximo	975.5	948.9	1631.27	916.28

Tabla 3.27: Sup: Valores medios de la cantidad acumulada estacional, observados y ajustados por el modelo en Tortosa (1942-1981). Inf.: Percentiles de los residuos por estaciones.

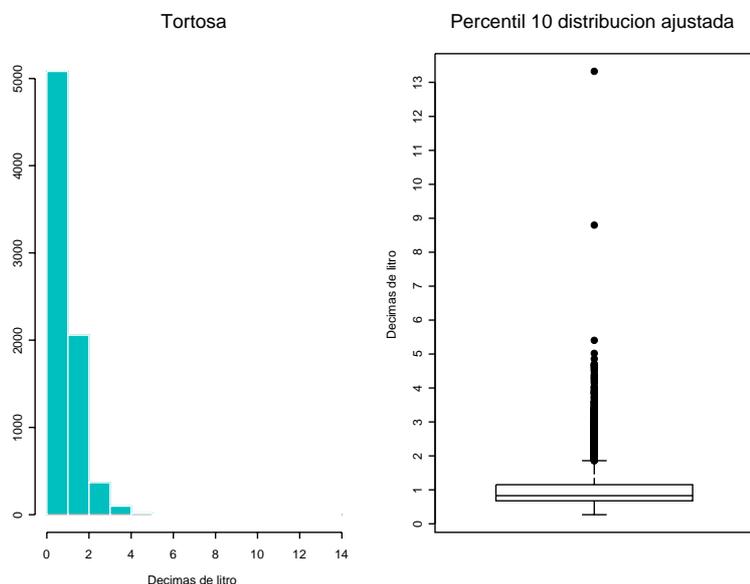


Figura 3.48: Histograma y diagrama de caja del percentil 10 de las distribuciones ajustadas por el modelo de cantidad, Tortosa (1942-1981).

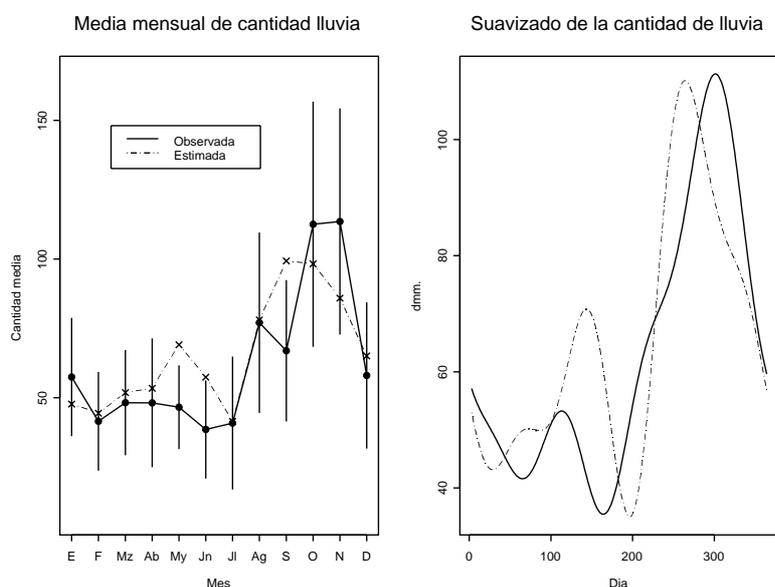


Figura 3.49: Izda.: Cantidad media observada y ajustada, por meses, con el modelo de cantidad, Tortosa (1982-1991). Dcha.: Suavizado de los valores diarios observados y ajustados.

40% menor en Abril. El percentil 95 es semejante en la mayoría de los meses excepto en el de Septiembre, donde las simulaciones producen un valor 13 litros menor que el observado.

### Comportamiento del modelo en el periodo de validación

El modelo reproduce en el periodo de validación el ciclo estacional ajustado en el de estimación, 1942-1981. En el periodo de validación, 1982-1991, la época con cantidades medias máximas se ha desplazado a los meses de Octubre y Noviembre y se observa una disminución importante de los valores medios de Mayo y Junio, ver figura 3.49. Esto se refleja en una reducción de los porcentajes de variabilidad explicada, ver tabla A.93, que en Verano e Invierno se encuentra prácticamente en el 0% y en las otras dos estaciones en un 5%. Se concluye por tanto que el modelo es demasiado rígido y que le falta información para adaptarse al nuevo periodo.

La tabla A.93 resume los resultados del análisis de las simulaciones en el periodo de validación. En general, la distribución simulada no se puede considerar idéntica a la observada; incluso en los meses donde el test KS proporciona p-valores por encima de 0.05 hay diferencias importantes entre

los percentiles de ambas distribuciones. La mediana obtenida con el modelo presenta una reducción del 30% en los meses de Enero y Agosto y un incremento del 50% en el de Abril, mientras que los percentiles 95 de Febrero, Mayo, Junio, Septiembre y Diciembre son superiores, entre un 40 y un 50%, a los valores observados. Las discrepancias en los percentiles no son del mismo signo que las que existían en el conjunto de estimación.

Se puede concluir que el modelo de cantidades para Tortosa es poco satisfactorio por razones semejantes a las comentadas en el modelo de Reinosa. Además, no reproduce adecuadamente un aspecto característico del clima mediterráneo litoral como son las precipitaciones intensas en el Otoño.

### 3.10.3 Modelo de cantidad en Agoncillo

El modelo ajustado en el observatorio de Agoncillo usando los datos en el periodo de estimación, 1978-1992, se presenta en la tabla A.94. Incluye como covariables significativas los armónicos hasta el orden 4, el rango de temperatura y la temperatura mínima en el día  $t$  y en el  $t - 1$  y las medidas de presión a las 0, 7 y 18 horas del día  $t$ , esta última, además, con efecto cuadrático. La lluvia en el día previo interviene sólo a través de la cantidad registrada, con un coeficiente que es del mismo orden que el estimado en Tortosa.

El modelo explica un 12.2% de variabilidad de la respuesta, con valores estacionales que van desde un 5.9% en Otoño al 12.7% en Invierno, ver tabla A.95. La inclusión de la información de presión no supone un incremento de la variabilidad explicada respecto a los valores alcanzados en observatorios anteriores, aunque, en éste, el modelo que contiene información de temperatura (no mostrado) explica un 8.1% de la variabilidad.

El modelo reproduce bien el ciclo estacional, ver figura 3.50, siendo el coeficiente de correlación asociado 0.93. El mismo análisis con los valores medios anuales resulta menos satisfactorio, ver figura 3.51, su coeficiente de correlación es 0.53 y el calculado con los valores medios de los meses observados es 0.59.

Las distribuciones ajustadas producen percentiles 10 que se sitúan por debajo de 1 décima de litro, ver figura 3.52, con lo que la frecuencia de observaciones menores que ese valor es, también en este caso, escasa.

La autocorrelación de orden 1 de los residuos no es significativa al 5% y sí lo era en el modelo con información de temperatura y presión que no

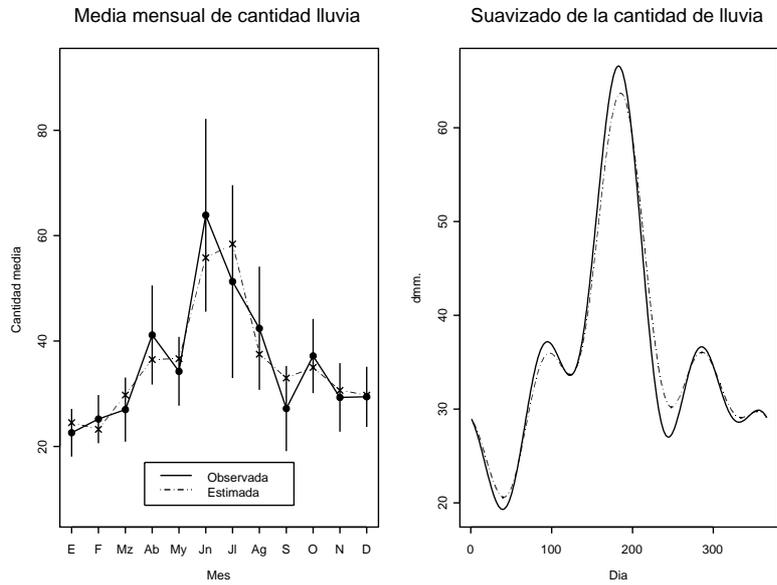


Figura 3.50: Izda.: Cantidad media observada y ajustada, por meses, con el modelo de cantidad, Agoncillo (1978-1992). Dcha.: Suavizado de los valores diarios observados y ajustados.

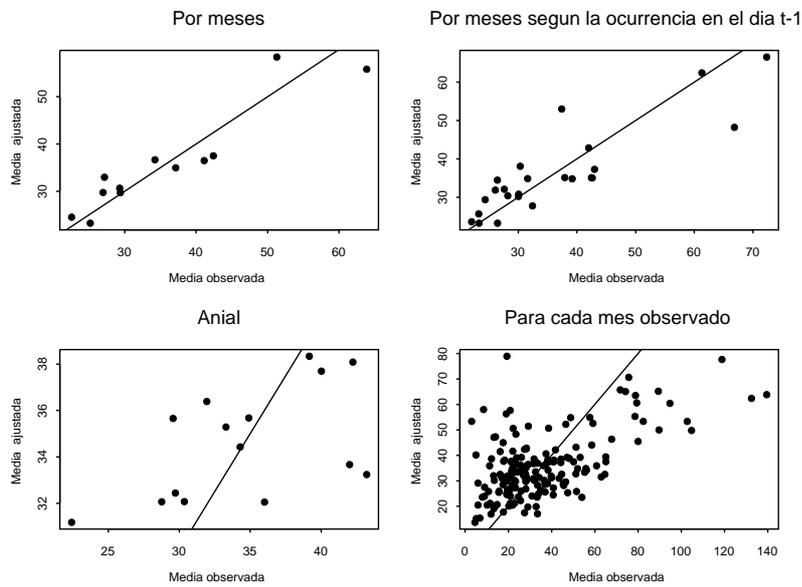


Figura 3.51: Diagramas de dispersión de las cantidades medias ajustadas vs. observadas en Agoncillo (1982-1991).

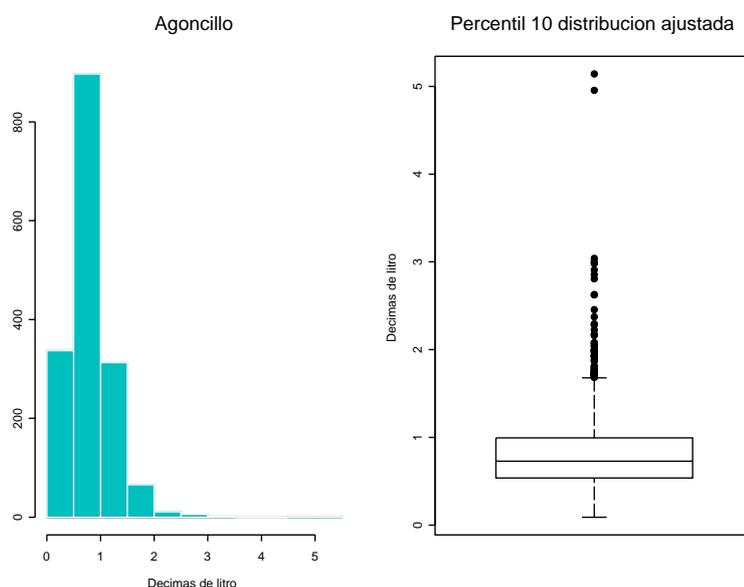


Figura 3.52: Histograma y diagrama de caja del percentil 10 de las distribuciones ajustadas, Agoncillo (1978-1992).

utilizaba la cantidad de lluvia en días previos.

La simulación del modelo de cantidad, utilizando las covariables observadas, proporciona resultados compatibles con las distribuciones observadas en los meses de Junio a Septiembre y discrepancias significativas, según el test KS, en los demás meses, ver tabla A.96. Se producen errores mayores que un 30% en las medianas de los meses de Marzo y Octubre.

### Comportamiento del modelo en el periodo de validación

La comparación entre el grado de ajuste en el periodo de validación, ver tabla A.97, y el alcanzado en el periodo de estimación, ver tabla A.95, indica que el modelo se comporta de forma semejante, globalmente, en ambos periodos. Por estaciones, la variabilidad explicada aumenta en Otoño hasta el 11.7%, mientras en Verano se produce una fuerte reducción.

En el periodo de validación, 1993-1997, el perfil de las cantidades medias observadas es distinto al del periodo de estimación, ver figura 3.53. En Octubre se observa el menor valor medio y los valores de Junio y Julio son superados por el de Diciembre, donde la media ajustada se encuentra separada de la observada más de 2 errores estándar. El suavizado de los valores

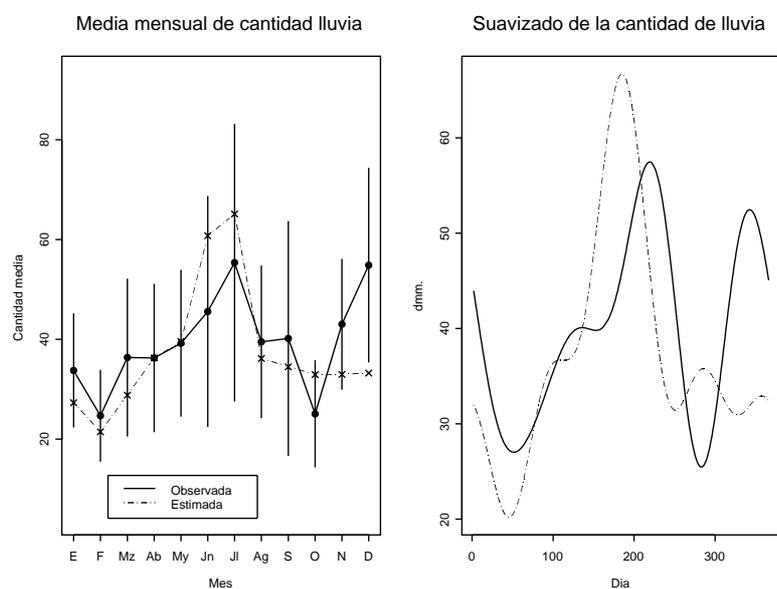


Figura 3.53: Izda.: Cantidad media observada y ajustada, por meses, Agoncillo (1993-1997). Dcha.: Suavizado de los valores diarios observados y ajustados.

ajustados reproduce el perfil del periodo de estimación y no el observado; el coeficiente de correlación entre los vectores de medias mensuales es sólo 0.65.

La clasificación de las cantidades observadas de acuerdo con los percentiles de la distribución ajustada es adecuada en los intervalos centrales y se aleja de lo esperado en las clases extremas. Cabe destacar que en los días iniciales de racha seca un 3% de las observaciones se clasifica por debajo del percentil 10. Se trata todavía de un porcentaje alejado del esperado pero supone un incremento respecto al valor obtenido en el periodo de estimación.

En el periodo de validación no se rechaza la igualdad de las distribuciones simuladas y observadas, ver tabla A.98, aunque esto puede deberse al menor tamaño de muestra. Las discrepancias entre los percentiles son del mismo orden que las encontradas en el conjunto de estimación, aunque no se producen en los mismos meses ni son del mismo signo. Las discrepancias son mayores que el 30% del valor observado en las medianas de los meses de Junio, Septiembre, Octubre, Noviembre y Diciembre.

Finalmente, cabe señalar que el modelo de cantidad en Agoncillo, que incorpora la información de presión atmosférica en superficie, no ha mejorado el porcentaje de variabilidad explicada obtenido en los modelos de Reinosa

y Tortosa ni ha resuelto la rigidez de esos modelos para representar un ciclo estacional distinto al existente en el periodo de estimación. Sin embargo, en Agoncillo, se obtienen mejores resultados en el porcentaje de variabilidad explicada en el periodo de validación, que no disminuye respecto al de estimación.

### 3.10.4 Modelos de cantidad en Zaragoza

En el observatorio de Zaragoza se ha ajustado, en primer lugar, un modelo de cantidades que usa como covariables la temperatura, presión y humedad en superficie, lo que permite valorar el grado de ajuste que se obtiene al incorporar la información de humedad. Posteriormente se presentan los resultados relativos a un modelo que incluye información del radiosondeo y del viento en superficie. En su proceso de ajuste se ha aplicado la estrategia usada en el modelo *CM sondeos*.

#### Modelo con información de superficie

En la tabla A.99 se muestra la composición del modelo ajustado en Zaragoza con información de superficie y sin considerar las variables que representan el viento. Notemos la significación de algunos efectos que han aparecido ya en anteriores modelos de cantidad: el rango de temperatura y la presión a las 18 horas. También es significativo el efecto de la presión a las 13 horas del día anterior, que requiere un término cuadrático. La humedad relativa interviene con sus medidas de las 13 y 18 horas; el efecto positivo de esta variable a las 18 horas, con uno de los mayores valores del estadístico  $t$ , es tal que un incremento del 10% supone multiplicar el valor ajustado por un factor  $\exp(\beta_{H18} \times 10) = 1.23$ . La memoria del proceso de lluvia incluye el marcador de ocurrencia en el día  $t - 1$  y no resulta significativo ningún efecto relativo a las cantidades registradas en días anteriores.

Como era de esperar, el grado de ajuste de este modelo es mayor que el alcanzado anteriormente, ver tabla A.100. El porcentaje de variabilidad explicada globalmente es un 36% y, estacionalmente, se obtienen valores entre un 29.6% en Otoño y un 41% en Invierno. Otro índice que indica un mejor ajuste es la clasificación de las cantidades observadas de acuerdo con su posición respecto a los cuantiles de la distribución ajustada: un 6% de los días tienen una precipitación por debajo del percentil 10, al mismo tiempo que los porcentajes se mantienen adecuados en los otros intervalos.

El modelo reproduce bien la estacionalidad del fenómeno, ver figura 3.54.

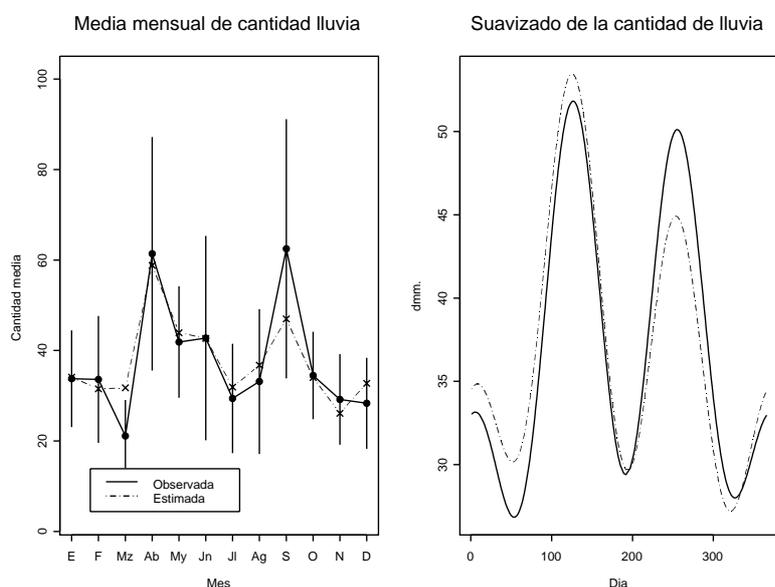


Figura 3.54: Izda.: Cantidad media observada y ajustada, por meses, con el modelo de superficie, Zaragoza (1990-1997). Dcha.: Suavizado de los valores diarios observados y ajustados.

En la figura 3.55 se aprecia que los doce valores medios mensuales ajustados y los observados están alrededor de la recta identidad; su coeficiente de correlación es 0.89. El valor del coeficiente de correlación entre los valores medios anuales es 0.89 y si se calcula entre los valores medios de cada mes, 0.81.

La figura 3.56 contiene gráficos relativos a los residuos de la deviance. El qq-plot Normal muestra que están próximos a esta distribución, aunque sigue existiendo una concentración en la cola izquierda, menos importante que la identificada en ajustes previos. Esta mejora no es suficiente para considerar el ajuste satisfactorio; el test KS de Normalidad proporciona un p-valor de 0.028.

### Modelo ajustado con información del radiosondeo

En la tabla A.102 se muestra la composición del modelo basado en la información más completa, que añade, a la del modelo anterior, la relativa a los niveles geopotenciales y la del viento en esos niveles y en superficie.

En el predictor lineal se requieren dos armónicos, uno menos que en el

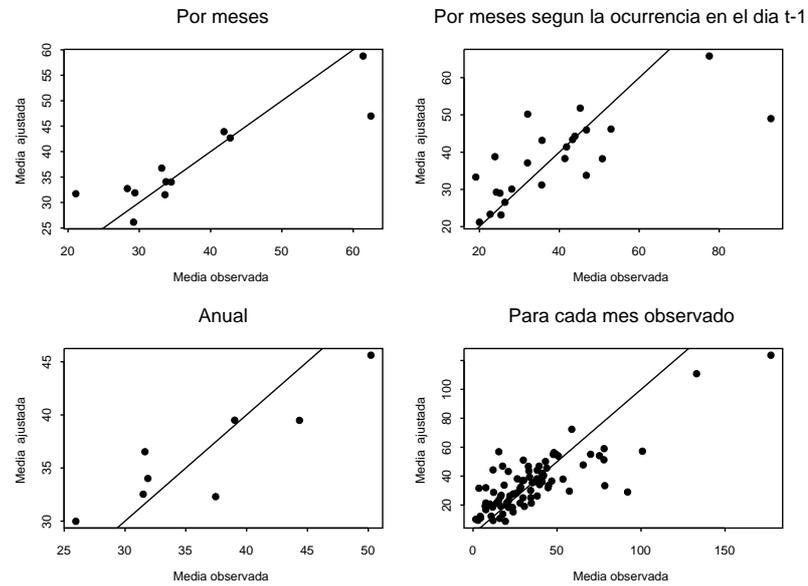


Figura 3.55: Diagramas de dispersión de las cantidades medias ajustadas con el modelo con información de superficie vs. observadas en Zaragoza (1990-1997).

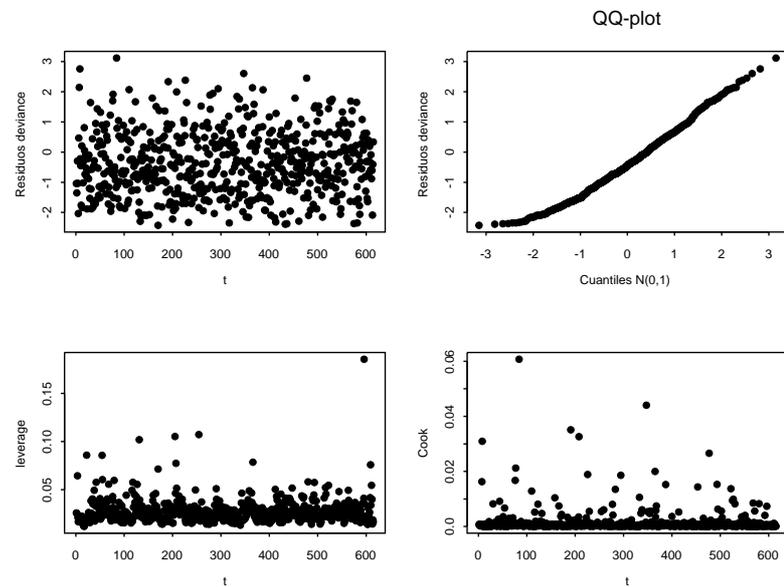


Figura 3.56: Gráficos basados en los residuos de la deviance y medidas de influencia del modelo que utiliza información de superficie en Zaragoza.

modelo anterior. La precipitación previa aparece a través del indicador de lluvia en el día  $t - 1$ . Las variables de superficie significativas son la temperatura, presión y humedad a las 18h, el rango de temperatura, todas ellas en el día  $t$ , y la presión a las 13 horas en el día previo. Los coeficientes de los términos que estaban ya en el modelo anterior son semejantes en éste.

En cuanto a las nuevas covariables, tienen efecto significativo la temperatura del punto de rocío y la anomalía de temperatura en el nivel geopotencial 700hPa. En el modelo aparecen términos ligados al viento: la velocidad en superficie a las 0 horas, que tiene coeficiente negativo si el viento procede del Noroeste y positivo si procede de otra dirección. La dirección del viento a las 0 horas en el geopotencial 500hPa, ver figura 3.57 izquierda, interviene cuando el viento en superficie tiene procedencia SW.

Los modelos ajustados en 12 localidades europeas por Beckmann y Buisland (2001) [20] están basados en información muy semejante a la que usa este modelo, procedente del reanálisis NCEP/NCAR (National Center for Environmental Prediction y National Center for Atmospheric Research, de los Estados Unidos). Los autores encuentran, en todos los observatorios, el efecto significativo de la humedad relativa en el geopotencial 700hPa. En los observatorios españoles que analizan, Munera y Salto de Bolarque, es significativo, además, el efecto de la altura y la vorticidad en el nivel 850hPa. Las componentes de viento en distintos niveles geopotenciales intervienen en todos los modelos salvo en los de los dos observatorios españoles.

El parámetro de dispersión estimado, 1.159, es menor que en el modelo con información de superficie,  $\hat{\nu} = 1.257$ , que a su vez era menor que el obtenido cuando se utilizaba sólo temperaturas,  $\hat{\nu} = 1.660$ . A mayor información en el predictor lineal, y cuanto mejor es el ajuste, el parámetro se aproxima más a 1, valor que corresponde a una distribución Exponencial.

Las medidas de la tabla A.103 muestran que este modelo proporciona el mejor ajuste alcanzado hasta el momento. Explica globalmente un 40% de la variabilidad, con un valor mínimo estacional en Otoño de un 34%.

La cantidad media mensual ajustada sólo se diferencia de la observada en más de 2 errores estándar en el mes de Marzo, ver figura 3.58. Pese al mejor ajuste en general, la reproducción del perfil estacional es peor que la lograda con el modelo que utiliza sólo información de superficie, que tiene un armónico más en el predictor. Los coeficientes de correlación entre los valores medios mensuales y anuales, 0.82 y 0.87, respectivamente, son menores que los correspondientes en el modelo anterior (0.89 en ambos casos), ver figura

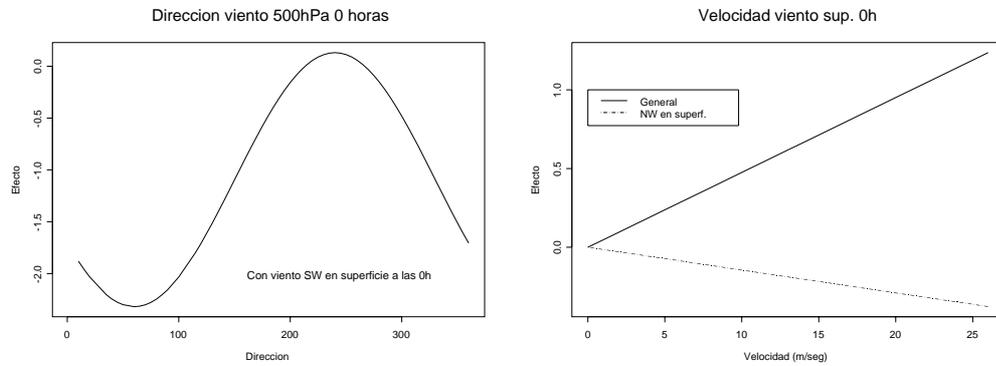


Figura 3.57: Efectos asociados a la dirección y velocidad del viento en el modelo con medidas del radiosondeo, Zaragoza. Izda.: Dirección del viento en el nivel 500hPa a las 0h, cuando en superficie hay viento SW. Dcha.: Velocidad del viento en superficie a las 0h.

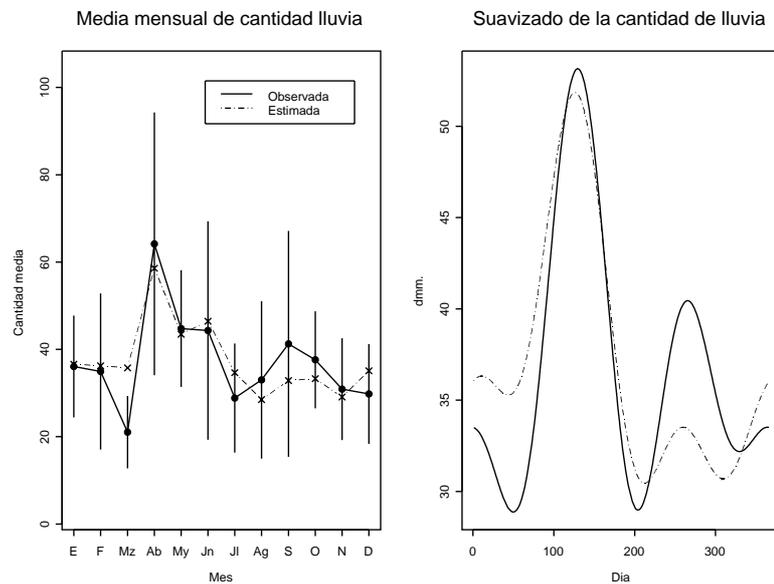


Figura 3.58: Izda.: Cantidad media observada y ajustada, por meses, con el modelo con información del radiosondeo, Zaragoza (1990-1997). Dcha.: Suavizado de los valores diarios observados y ajustados.

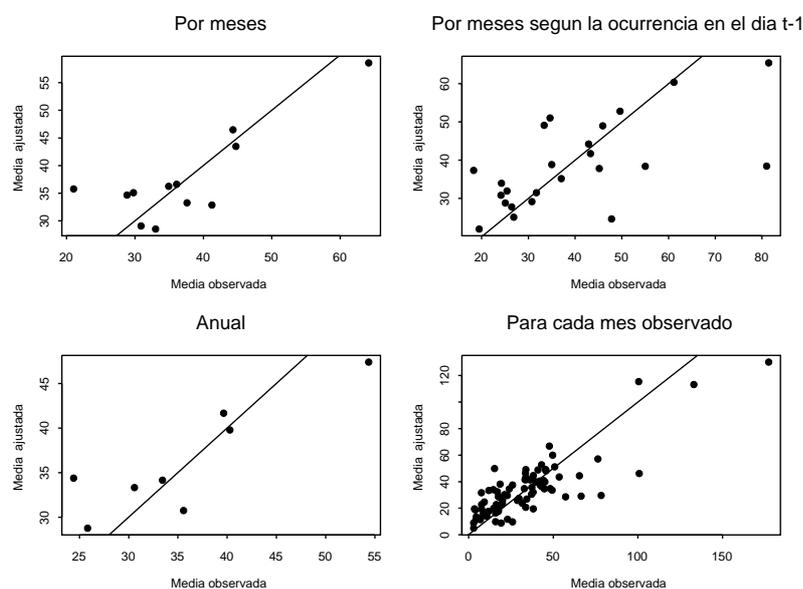


Figura 3.59: Diagramas de dispersión de las cantidades medias ajustadas con el modelo que usa información del radiosondeo vs. observadas en Zaragoza (1990-1997).

3.59 y tabla A.103. Notemos que el perfil suavizado de la cantidad media en el periodo 1990-1997 se obtiene a partir de los días con dos medidas de radiosondeo, por lo que no es estrictamente comparable con el de la figura 3.54, en el que se utilizan todos los días; las cantidades muestran diferente comportamiento, sobre todo en el mes de Septiembre, ver figura 3.60.

Con el modelo más complejo se obtiene una buena clasificación de las cantidades observadas según los percentiles de la distribución ajustada: un 9.5% de las observaciones se encuentran sobre el percentil 90 y un 7.5% bajo el percentil 10, debido a que las distribuciones ajustadas producen valores de este percentil mayores que 2 décimas de litro en la mitad de los días, ver figura 3.61.

El test KS no rechaza la Normalidad de los residuos de la deviance, con un p-valor de 0.50. En el qq-plot Normal, ver figura 3.62, se aprecia que la concentración en la parte izquierda del rango es sensiblemente menor que en otros modelos, lo que permite concluir que la distribución Gamma puede ser adecuada cuando se cuenta con información suficiente.

El análisis de las 20 simulaciones efectuadas con este modelo se resume

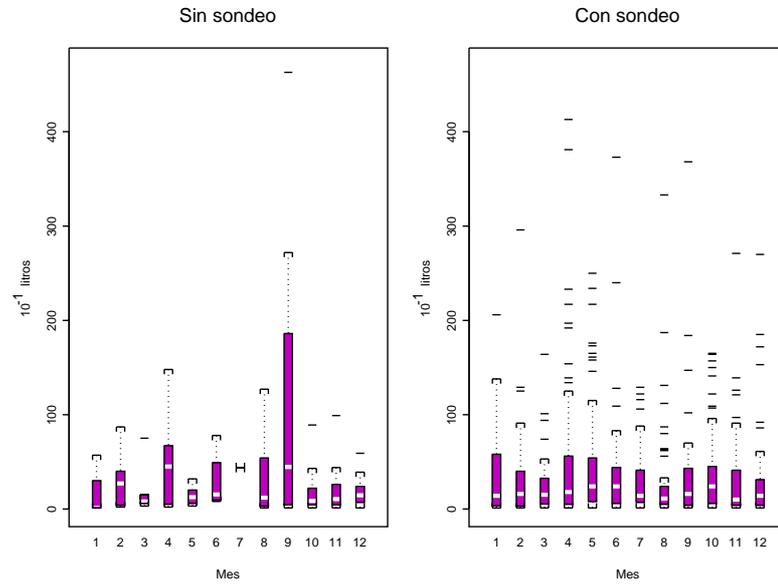


Figura 3.60: Diagramas de caja de las cantidades observadas en días con y sin radiosondeo, por meses, Zaragoza (1990-1997).

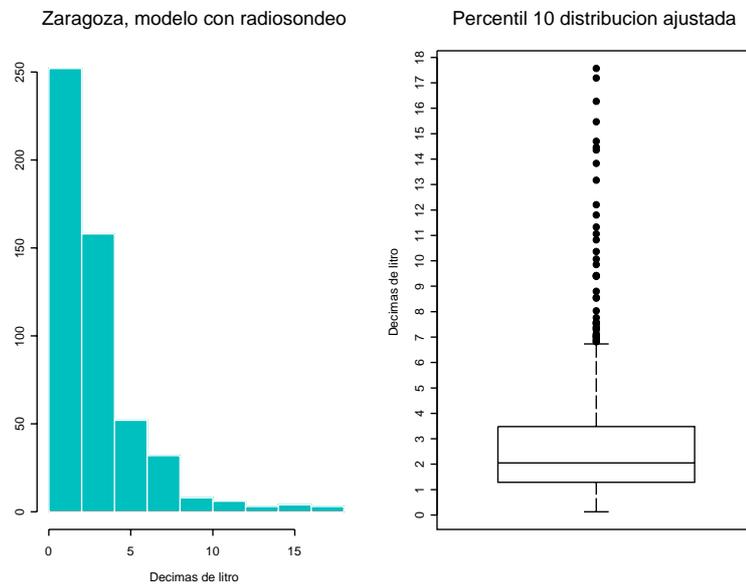


Figura 3.61: Histograma y diagrama de caja del percentil 10 de las distribuciones ajustadas por el modelo con información del radiosondeo, Zaragoza (1990-1997).

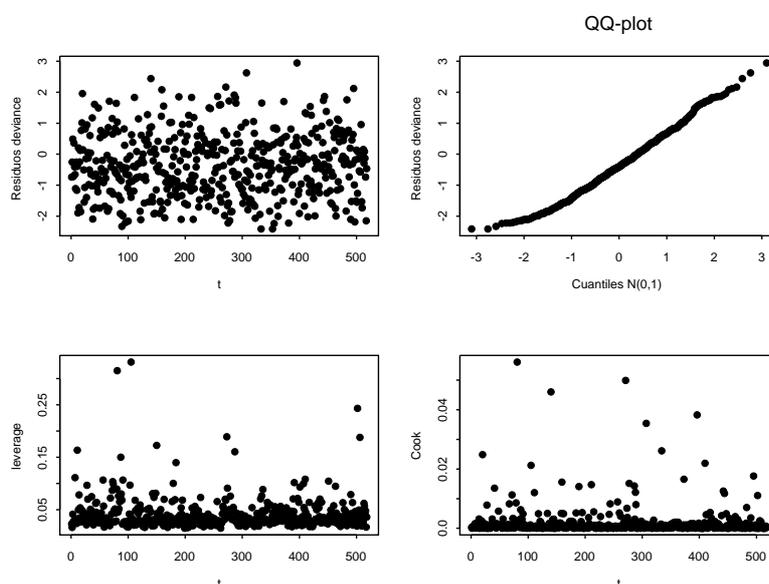


Figura 3.62: Gráficos basados en los residuos de la deviance y medidas de influencia del modelo que utiliza información del radiosondeo.

en la tabla A.104. La distribución de los datos generados en cada mes no se distingue de la observada, según el test KS. Errores superiores al 30% del valor observado aparecen en el percentil 95 de Enero y Marzo y en las medianas de Septiembre, Febrero y Octubre.

### Comportamiento del modelo en el periodo de validación

En el conjunto de validación el modelo sufre una fuerte reducción de la variabilidad explicada, tanto globalmente, con un porcentaje de un 21%, como por estaciones: el mayor valor, en Primavera, es un 28%.

Esta disminución del porcentaje de variabilidad explicada es provocada por el mal ajuste en unas pocas observaciones. En cada estación se ha identificado el dato en el que la discrepancia con el valor ajustado es máxima de acuerdo con el criterio:

$$\left| \frac{Q_t - \hat{Q}_t}{Q_t - \bar{Q}_t} \right|$$

donde  $Q_t$  es la cantidad observada,  $\hat{Q}_t$  la ajustada y  $\bar{Q}_t$  es el valor medio de la cantidad de lluvia en ese día, obtenido mediante un suavizado de la respuesta.

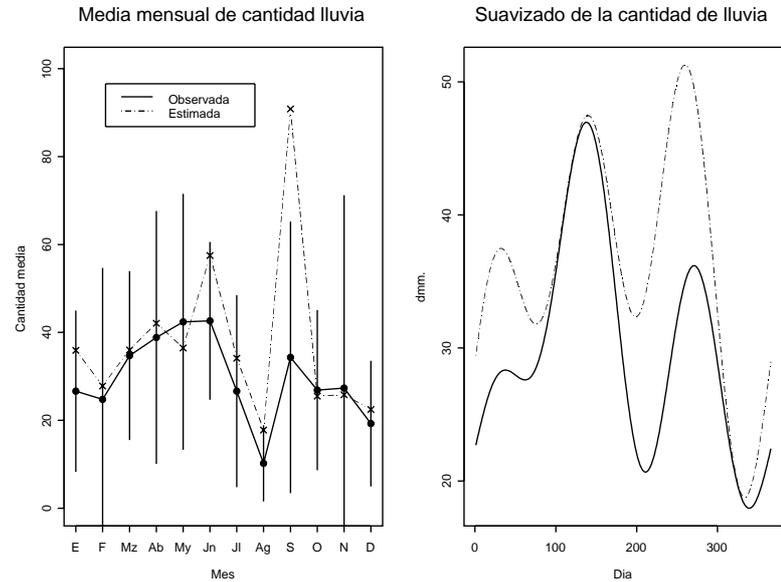


Figura 3.63: Izda.: Cantidad media observada y ajustada, por meses, con el modelo de cantidad que utiliza información de radiosondeos, Zaragoza (1998-2000). Dcha.: Suavizado de los valores diarios observados y ajustados.

Al calcular el porcentaje de variabilidad explicada retirando ese dato, se obtienen valores de un 35.2% en Primavera, un 35.4% en el Verano, un 28.6 en el Otoño y un 20.9% en el Invierno. Veremos en la subsección 3.10.5 que la influencia de estos datos mal ajustados no es tanta cuando el tamaño muestral es mayor.

La figura 3.63 muestra la mala reproducción del ciclo estacional en el conjunto de validación, en el que se obtiene un coeficiente de correlación de 0.58 entre los valores medios mensuales observados y ajustados. El suavizado proporciona valores medios semejantes en Primavera y diferencias apreciables en Otoño, donde destaca el mes de Septiembre en el que las cantidades ajustadas alcanzan valores máximos anuales, en contradicción con lo observado.

La tabla A.106 contiene información sobre los resultados de la simulación del modelo en este periodo. Debido al pequeño tamaño de muestra no hay evidencia suficiente para considerar distintas las distribuciones observada y simulada pero en la mayoría de los meses aparecen discrepancias superiores al 30% del valor observado en la mediana y en el percentil 95. La mediana observada en cada mes, salvo en los de Junio, Septiembre y Octubre, indica un periodo de menor intensidad de la lluvia en relación con el periodo de es-

timación, un cambio que no se produce en la mediana de los datos simulados, lo que indica que el modelo no logra reproducir la variabilidad interanual.

### 3.10.5 Conclusiones

En esta subsección se presentan las conclusiones más destacables sobre el proceso de modelización de cantidades realizado. En primer lugar se establecen algunas de carácter general y posteriormente se comparan y analizan los resultados obtenidos en los modelos de los cuatro observatorios, en cuanto a su predictor lineal, el grado de ajuste y la reproducción de las propiedades agregadas.

#### Conclusiones de carácter general

El procedimiento de modelización propuesto es capaz de reproducir la señal cuando se incluye en el predictor lineal la información climática pertinente. La mejora que ha supuesto el uso de variables atmosféricas se ha reflejado tanto en la variabilidad explicada como en el buen comportamiento de los residuos.

Los modelos que sólo utilizan temperatura y presión en superficie explican poca variabilidad, un 12.2% en Agoncillo y un 26.1% en Zaragoza (modelo no mostrado). La inclusión de información de humedad en superficie da lugar a un incremento importante en ese porcentaje, un 36% en Zaragoza. El modelo con información de altura explica más del 40%.

Para valorar los resultados obtenidos conviene compararlos con los de Beckmann y Buishand (2001) [20] en los 12 observatorios europeos estudiados. El porcentaje de variabilidad explicada alcanza en los observatorios de Holanda, Suiza, Alemania y Austria valores que oscilan entre un 21.5% y un 33.3%. En los dos observatorios españoles que estudian, los modelos retienen menos covariables significativas que en los demás: el agua precipitable, la altura y la vorticidad en el geopotencial 850hPa. Con ellas, los modelos explican un 13.3% de la variabilidad en Salto de Bolarque (Guadalajara) y un 9% en Munera (Albacete), valores comparables a los obtenidos en los ajustes de Reinoso, Tortosa y Agoncillo usando menos información.

En relación con las distribuciones ajustadas, sólo en el observatorio de Zaragoza se obtienen resultados satisfactorios en la clasificación de los datos según las categorías definidas por los percentiles 10, 25, 75 y 90 de la distribución ajustada. En los demás, las distribuciones Gamma ajustadas proporcionan, en la mayoría de los casos, un percentil 10 menor que 1 décima de litro, la cantidad mínima registrada.

La causa de este problema, que aparece en los modelos que utilizan poca

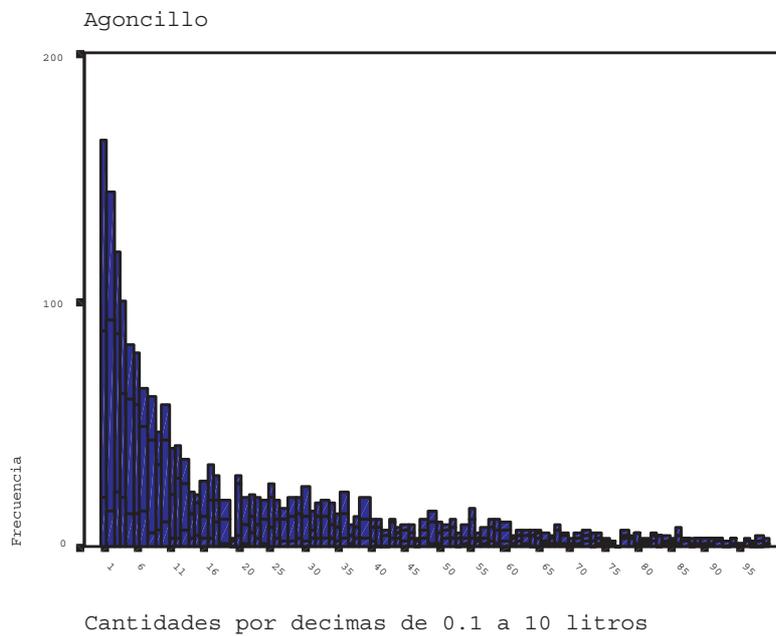
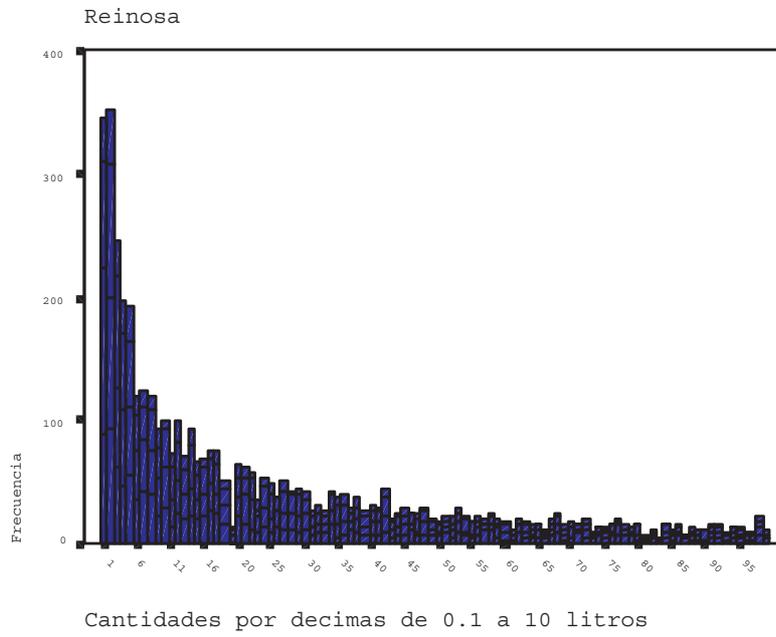


Figura 3.64: Frecuencias de las cantidades de lluvia positivas, entre 1 y 100 décimas de litro, en Reinosa y Agoncillo.

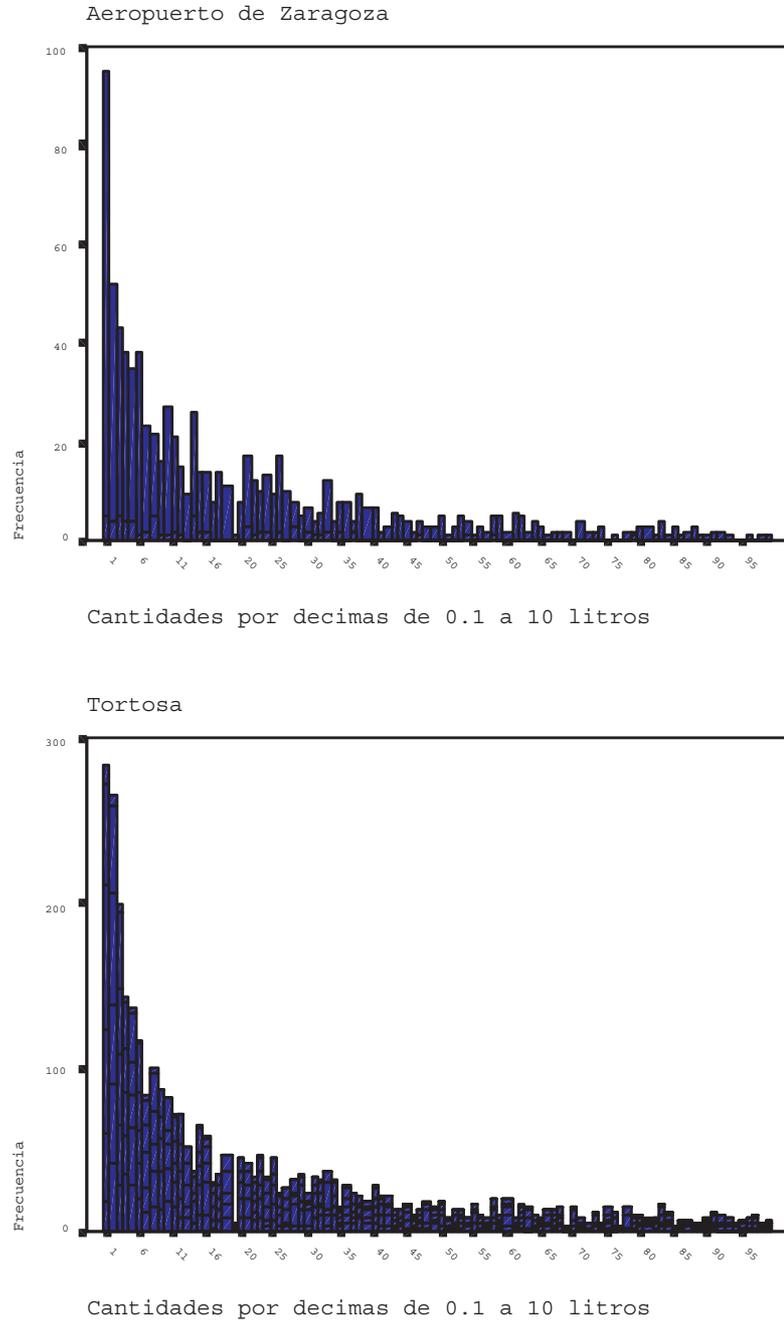


Figura 3.65: Frecuencias de las cantidades de lluvia positivas, entre 1 y 100 décimas de litro, en Zaragoza y Tortosa.

información, hay que buscarla en las características de la respuesta. Las cantidades observadas, como se ve en las figuras 3.64 y 3.65, toman con gran frecuencia valores pequeños. Un modelo con pocas covariables diferencia pocas situaciones experimentales, de modo que ajusta la misma distribución y valor esperado para días con cantidades registradas muy distintas, entre las que abundan las de 1 décima de litro o cercanas; por ello los residuos delatan una fuerte concentración en la cola izquierda.

La inclusión de covariables en el predictor lineal permite distinguir situaciones según el estado atmosférico, en las que el rango de variación de las cantidades es mucho menor. A la vista de los resultados obtenidos, la información de temperatura y presión resulta insuficiente para resolver este problema, mientras que el uso de la humedad relativa, de las variables de viento y del radiosondeo mejora el ajuste. Interesa señalar que la mayor proporción de valores de 1 décima de litro se produce en Zaragoza, único observatorio donde este problema se acaba resolviendo.

En nuestra opinión, esta insuficiencia que presentan los modelos de cantidades no se debe a que la distribución del error sea inadecuada sino a la falta de información climática en los mismos.

### Modelo ajustado

Tras el análisis de los predictores obtenidos en los diferentes observatorios, cabe destacar:

- Se constata la dependencia entre las observaciones consecutivas de cantidad en los cuatro observatorios estudiados, lo que lleva a considerar extensiones condicionales de los GLM. En la figura 3.66 se muestra el efecto de la cantidad previa en los modelos de Reinosa, Tortosa y Agoncillo, de carácter no lineal en los dos primeros. En todos los casos, el nivel medio de lluvia se incrementa con la cantidad registrada en el día anterior. En los modelos de Zaragoza no aparece la cantidad previa como covariable; esto no es debido a su sustitución por otra información climática ya que, en el modelo que contiene sólo la temperatura tampoco tiene un efecto significativo.

El efecto de los indicadores de ocurrencia en los días anteriores es significativo en los modelos de Reinosa y Zaragoza y en ambos casos supone un incremento en el predictor lineal.

- El rango de temperatura es significativo en los modelos de cantidad. En la figura 3.67 se representa su efecto en los modelos ajustados. Si

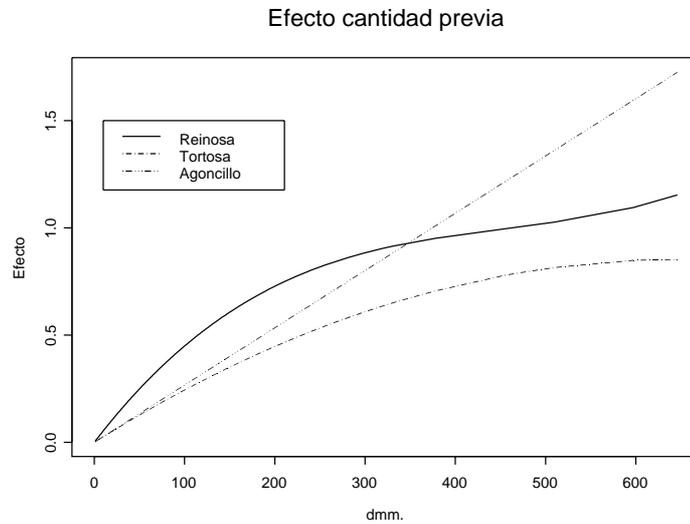


Figura 3.66: Efecto de la cantidad en el día previo en los distintos modelos en que interviene.

se comparan los coeficientes de su término lineal se comprueba que siempre son negativos,  $-0.020$  en Reinosa,  $-0.016$  en Tortosa,  $-0.006$  en Agoncillo,  $-0.013$  en Zaragoza con información de superficie,  $-0.016$  en Zaragoza con información del radiosondeo. En el modelo de Reinosa y en los de Zaragoza su efecto es no lineal; en este último observatorio y para valores grandes del rango, llega a ser positivo.

- La humedad relativa tiene un efecto significativo que se mantiene en el modelo cuando se incluye información sobre el viento y el radiosondeo.

En los modelos ajustados el parámetro de dispersión se reduce según se va incluyendo más información y la distribución Gamma se va aproximando a un modelo Exponencial: en Reinosa y Tortosa se obtienen estimaciones de 1.97 y 2.83, respectivamente, en Agoncillo 1.80, en Zaragoza, en el modelo de superficie 1.26 y en el que usa información de radiosondeo 1.16.

El coeficiente de variación de una distribución Gamma no depende del valor esperado. Para analizar esta hipótesis, McCullagh y Nelder recomiendan establecer grupos de observaciones, de acuerdo con el valor ajustado, y calcular el coeficiente de variación en cada grupo. En la figura 3.68 se presentan los coeficientes de variación calculados haciendo 10 grupos de igual tamaño. Se comprueba la estabilidad de este estadístico en Reinosa, Agoncillo y Zaragoza; en Tortosa, el coeficiente cambia cuando la media supera el

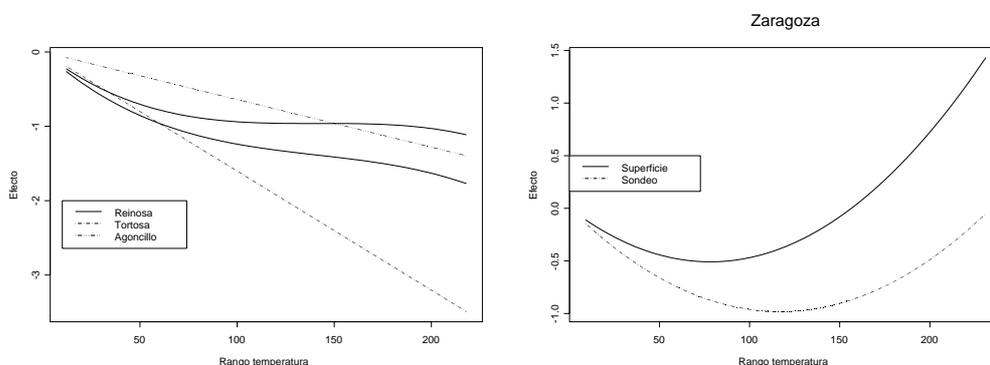


Figura 3.67: Efecto del rango de temperatura en los distintos modelos de cantidad.

Observ.	Datos	Global	Primavera	Verano	Otoño	Invierno
Reinosa	Estim.	14.83	12.92	0.42	9.93	21.17
	Valid.	7.19	8.02	0	8.82	6.2
Tortosa	Estim.	16.47	16.46	6.67	15.82	15.52
	Valid.	8.01	6.29	0.31	5.55	0.69
Agoncillo	Estim.	12.24	10.23	9.08	5.94	12.72
	Valid.	10.53	14.25	1.16	11.74	13.43
Zaragoza (superficie)	Estim.	36.43	40.7	37.58	29.61	41.7
	Valid.	21.08	46.19	0	0	0
Zaragoza (sondeo)	Estim.	40.24	50.92	36.69	33.77	34.61
	Valid.	20.82	28.13	0	8.22	5.47

Tabla 3.28: Porcentaje de variabilidad explicada, global y estacionalmente, en los conjuntos de estimación y validación.

valor de 5 litros/m<sup>2</sup> por lo que el modelo no se puede considerar correcto. Este problema podría resolverse incluyendo información adicional o ajustando diferentes modelos Gamma según las estaciones.

### Bondad de ajuste

La tabla 3.28 contiene los porcentajes de variabilidad explicada por los modelos, tanto globalmente como por estaciones, en los conjuntos de estimación y validación. De su análisis cabe destacar:

- Los modelos que utilizan información de temperatura explican un porcentaje de variabilidad escaso. El uso adicional de la presión permite mejorar algo ese porcentaje: en Agoncillo se pasa de un 8.1% a un 12.2% y en Zaragoza de un 15.5% a un 26.1%. La inclusión de la

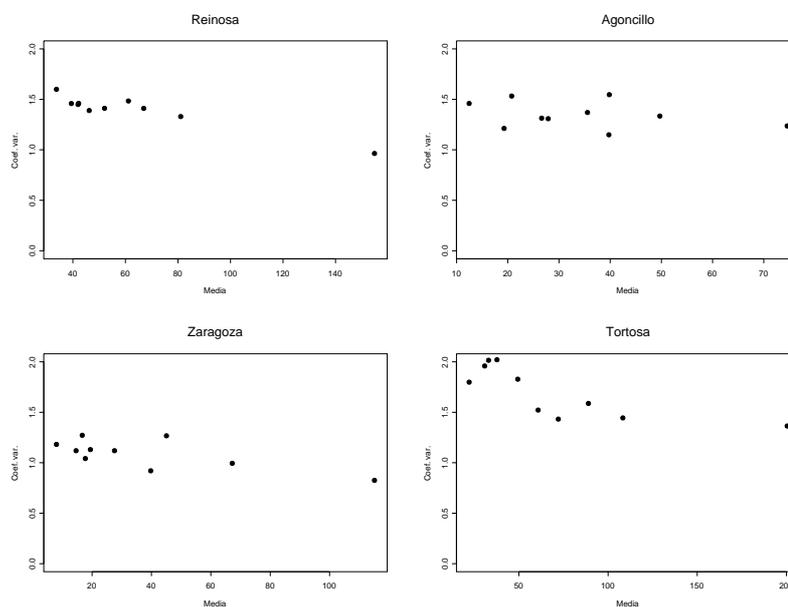


Figura 3.68: Coeficiente de variación frente a cantidad media en 10 grupos de observaciones seleccionadas según el valor ajustado del modelo de cantidad. En Zaragoza se usa el modelo más completo.

humedad relativa incrementa fuertemente la variabilidad explicada y, por último, la adición de la información de viento y del radiosondeo aumenta ligeramente ese porcentaje.

- El Verano está mal representado en Reinosa y Tortosa, con porcentajes de variabilidad explicada 9 puntos menores a los de las otras estaciones. En Agoncillo y Zaragoza el porcentaje del Verano es similar al alcanzado en Primavera o Invierno. En esos dos observatorios, el Otoño es la estación con menor variabilidad explicada.
- Observamos en 4 de los 5 modelos que se produce una disminución, de un factor cercano a 0.5, en la variabilidad explicada en el conjunto de validación. Por estaciones la mayor reducción se produce en el Invierno. El modelo que utiliza presión y temperatura en el observatorio de Agoncillo explica en todas las estaciones, menos en Verano, mayor porcentaje de variabilidad en el conjunto de validación que en el de estimación.

El modelo de superficie de Zaragoza proporciona un buen resultado en el conjunto de estimación y muestra un descenso apreciable en el periodo de validación debido al mal ajuste de algunas observaciones

Observ.	Datos		Global	Primavera	Verano	Otoño	Invierno
Reinosa	Estim.	Todos	14.83	12.92	0.42	9.93	21.17
		Sin	14.85	12.97	0.43	9.96	21.23
	Valid.	Todos	7.19	8.02	0	8.82	6.2
		Sin	7.21	8.08	0	8.99	6.36
Tortosa	Estim.	Todos	16.47	16.46	6.67	15.82	15.52
		Sin	16.47	16.66	6.69	15.92	15.67
	Valid.	Todos	8.01	6.29	0.31	5.55	0.69
		Sin	8.5	6.69	1.27	5.66	0.84
Agoncillo	Estim.	Todos	12.24	10.23	9.08	5.94	12.72
		Sin	12.25	10.28	9.12	6.02	12.81
	Valid.	Todos	10.53	14.25	1.16	11.74	13.43
		Sin	10.56	14.26	1.88	11.81	13.44
Zaragoza (superficie)	Estim.	Todos	36.43	40.7	37.58	29.61	41.7
		Sin	36.47	41.48	38.33	29.67	43.46
	Valid.	Todos	21.08	46.19	0	0	0
		Sin	21.1	47.69	0	0	0
Zaragoza (sondeo)	Estim.	Todos	40.24	50.92	36.69	33.77	34.61
		Sin	41.47	50.95	37.09	33.78	34.78
	Valid.	Todos	20.82	28.13	0	8.22	5.47
		Sin	20.83	35.2	35.44	28.69	20.89

Tabla 3.29: Porcentaje de variabilidad explicada, global y estacionalmente, en los conjuntos de estimación y validación, con todos los datos y prescindiendo del dato más discrepante.

en las estaciones distintas de la Primavera; algo similar, aunque menos extremo, ocurre en el modelo del radiosondeo.

- Como se ha indicado al analizar los modelos en Zaragoza, el porcentaje de variabilidad explicada en el periodo de validación, cuyo número de observaciones varía entre 38, en Verano, y 89, en Primavera, resulta muy sensible a la presencia de algún dato mal ajustado. Al volver a calcular este porcentaje sin utilizar el dato más discrepante en el sentido definido en la subsección anterior, los resultados, ver tabla 3.29, no muestran cambios notables en los conjuntos de datos numerosos pero sí en el modelo de Zaragoza con información de altura y viento. Para éste los nuevos porcentajes en Verano y Otoño son casi tan satisfactorios como los obtenidos en el periodo de estimación. En el modelo con información de superficie es necesario retirar más datos para que la variabilidad explicada sea positiva; en Otoño se obtiene un 21% retirando

Observ.	Datos	%var. expl.	Coef. correl.	Coef. efic.	Índ. acuerdo	%medio error
Reinosa	Estim.	14.83	0.766	0.450	0.699	1.467
	Valid.	7.19	0.494	-0.347	0.515	12.610
Tortosa	Estim.	16.47	0.546	0.287	0.696	4.660
	Valid.	8.01	0.280	-0.023	0.445	11.280
Agoncillo	Estim.	12.24	0.528	0.263	0.601	2.452
	Valid.	10.53	0.800	0.181	0.591	6.226
Zaragoza (superficie)	Estim.	36.43	0.891	0.732	0.897	1.032
	Valid.	21.08	0.859	0.0968	0.771	23.860
Zaragoza (sondeo)	Estim.	40.24	0.870	0.700	0.883	5.085
	Valid.	20.82	0.728	0.250	0.725	23.440

Tabla 3.30: Medidas de bondad de ajuste basadas en la media anual de la cantidad diaria para los modelos ajustados en los cuatro observatorios.

los 5 datos más discrepantes y en Invierno un 8.7% prescindiendo de 2.

Los índices y coeficientes calculados a partir de las medias observadas y ajustadas por meses y años proporcionan una visión complementaria del modelo. El coeficiente de correlación, que permite valorar hasta qué punto se reproduce el orden observado, puede tomar valores elevados en modelos que explican poca variabilidad, por ejemplo en el de Reinosa en el periodo de estimación, de 48 años de longitud, o en Agoncillo en el conjunto de validación, de 5 años, ver tabla 3.30.

El coeficiente de eficiencia se puede interpretar como un porcentaje de variabilidad explicada de los valores medios observados. En el caso de las medias anuales, la tabla 3.30 muestra que el modelo las reproduce mejor en el periodo de estimación que en el de validación, donde se tienen valores pequeños en el caso de Agoncillo y Zaragoza e incluso valores negativos en los modelos que emplean sólo temperatura. La figura 3.69 muestra los valores medios anuales de los datos observados y ajustados, éstos indicados con una cruz, en Tortosa. Hemos unido con un trazo continuo los puntos de aquellos años en los que la distancia entre la media observada y la ajustada es mayor, en valor absoluto, que la distancia de la media anual observada al valor medio de las medias anuales. Como se aprecia en la figura el número de esas discrepancias, en el periodo de validación, aumenta hasta un 50%.

El índice de acuerdo de las medias anuales tiene un comportamiento semejante al del coeficiente de correlación; cabe destacar que en el periodo de validación en Zaragoza, de sólo tres años de longitud, se obtienen valores

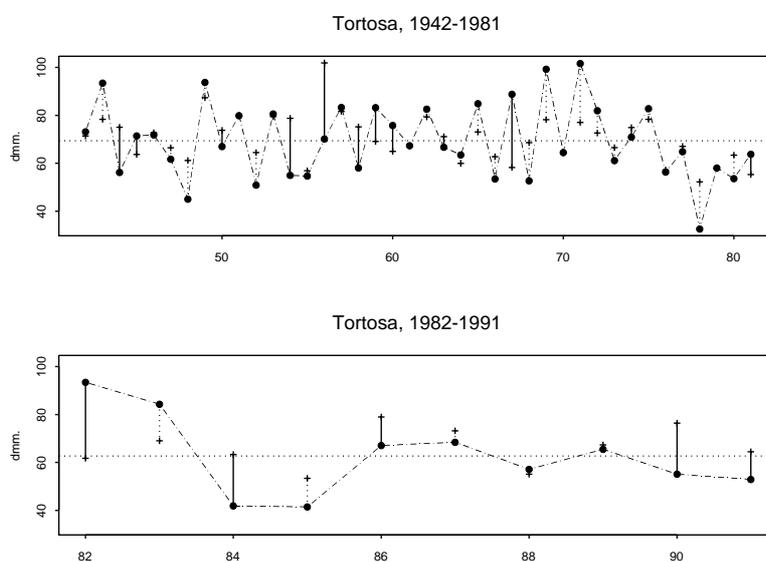


Figura 3.69: Media anual de las cantidades positivas observadas y ajustadas en Tortosa, en los periodos de estimación y validación.

altos de este índice a la vez que altos porcentajes medios de error.

Al analizar los valores medios mensuales, ver tabla 3.31, observamos que en el periodo de estimación, el coeficiente de correlación varía entre 0.82 para el modelo del radiosondeo en Zaragoza y 0.97 para el de Tortosa, lo que indica que los modelos reproducen mejor la estacionalidad del fenómeno que la variabilidad interanual. La reproducción de las medias mensuales en el periodo de validación es algo peor que en el de estimación en los modelos de Tortosa y Reinoso, donde el largo periodo de ajuste permite captar la variabilidad anual y el amplio periodo de validación hace que el ciclo anual sea más robusto. Por contra, en Agoncillo y Zaragoza, en donde la estacionalidad que se observa en el periodo de validación está alterada respecto a la observada en el de estimación, tanto los coeficientes de correlación y eficiencia como el índice de acuerdo muestran reducciones más drásticas. En los dos modelos ajustados en Zaragoza existen, en el periodo 1998-2000, meses con importantes diferencias entre los valores medios observados y ajustados, lo que provoca peores valores en estos coeficientes e índices, a pesar de que los modelos explican más variabilidad.

Observ.	Datos	%var. expl.	Coef. correl.	Coef. efic.	Índ. acuerdo	%medio error
Reinosa	Estim.	14.83	0.953	0.898	0.970	0.669
	Valid.	7.19	0.841	0.373	0.849	9.912
Tortosa	Estim.	16.47	0.971	0.934	0.981	1.185
	Valid.	8.01	0.782	0.592	0.859	10.980
Agoncillo	Estim.	12.24	0.930	0.863	0.961	1.465
	Valid.	10.53	0.654	-0.089	0.785	4.601
Zaragoza (superficie)	Estim.	36.43	0.896	0.766	0.915	3.673
	Valid.	21.08	0.468	-2.540	0.540	19.710
Zaragoza (sondeo)	Estim.	40.24	0.820	0.668	0.886	4.587
	Valid.	20.82	0.576	-2.665	0.571	29.430

Tabla 3.31: Medidas de bondad de ajuste basadas en la media de la cantidad diaria, por meses, para los modelos ajustados en los cuatro observatorios.

### Valoración final

Los modelos de cantidad resultan menos satisfactorios que los del proceso de ocurrencia. No obstante, como se ha señalado al comienzo de esta subsección, la metodología propuesta permite obtener ajustes prometedores cuando se dispone de información suficiente. En consecuencia, las mejoras que pueden ensayarse en estos modelos coinciden en buena parte con las indicadas para el modelo de ocurrencia:

- El uso de la información procedente de un reanálisis será útil en aquellos observatorios en los que no se dispone de radiosondeo y también para ampliar la información disponible en los que éste existe. Debe tenerse en cuenta, sin embargo, que variables relevantes como la humedad o el viento en superficie pueden, por diferentes motivos, no estar bien representadas en el reanálisis.
- Debe valorarse la posibilidad de construir modelos diferentes en épocas en las que la precipitación tiene un carácter especial, caso de las lluvias de Otoño en Tortosa. En ese sentido, cabe ensayar un predictor lineal que incluya un factor que caracterice las estaciones e interaccione con las covariables y también modificar el parámetro de dispersión ajustando modelos Gamma diferenciados por estaciones.

### 3.11 Líneas abiertas de investigación

La metodología presentada en este capítulo proporciona modelos de lluvia diaria útiles. Se han detectado en ellos algunos problemas a los que se debe buscar solución.

Existe un inconveniente para el desarrollo de modelos que aproximen bien el fenómeno en la escala diaria en aquellos observatorios en los que se carece de información sobre la troposfera, que son la gran mayoría. Por otra parte, cuando esa información está disponible, el periodo de estudio se restringe mucho. Como se ha comentado a lo largo del capítulo y se reitera en el capítulo 5, los modelos pueden ‘alimentarse’ con la información que proporciona algún reanálisis. Éstos disponen de información de las variables atmosféricas de superficie y altura en los puntos de una red que cubre todo el planeta. El del NCEP/NCAR proporciona datos cada 6 horas en una red de  $2.5^\circ \times 2.5^\circ$  a los que la Climatic Research Unit (CRU) facilita un rápido acceso, en el caso de la zona europea. Datos de este reanálisis han sido utilizados en trabajos de Wilby y Wigley (2000) [119], González-Rouco y otros (2000) [47], Cavazos (2000) [26] o Beckmann y Buishand (2001) [20]. Los datos del reanálisis ERA-40 desarrollado por el ECMWF (European Centre for Medium-Range Weather Forecasts) resultan de acceso más restringido.

El uso de esta información presenta varias ventajas:

- Permitiría obtener ajustes en observatorios no profesionales con una buena calidad en sus medidas y que representan áreas de interés.
- Incluso para observatorios como el de Zaragoza, donde la información es muy completa, el reanálisis puede ayudar a la representación de la situación atmosférica regional suministrando información del entorno. De este modo, se pasaría de trabajar con la información en un punto a utilizar campos de variables atmosféricas.

En la segunda versión del reanálisis NCEP/NCAR (NCEP/DOE AMIP-II Reanalysis) se dispone de información en altura y superficie a partir del año 1979, un intervalo temporal mayor que el que se ha utilizado en el modelo de Zaragoza.

El trabajo realizado junto con la experiencia de otros especialistas en la modelización de la lluvia, sugieren algunas mejoras:

- La clasificación de los días mediante la comparación de su dato de ocurrencia con la probabilidad ajustada por el modelo es una buena

herramienta para detectar insuficiencias. En esta memoria se ha llevado a cabo usando dos umbrales distintos, el valor 0.5 y la frecuencia relativa observada. En regímenes en los que esta frecuencia es pequeña, como ocurre en el centro de la depresión del Ebro, los dos umbrales están muy distantes y las clasificaciones obtenidas con ellos favorecen bien los días clasificados secos (con el umbral 0.5) o los días definidos húmedos (con la frecuencia relativa como umbral). Por ello nos proponemos ensayar un umbral que combine adecuadamente ambos valores.

- La distribución Gamma con un valor medio pequeño y un parámetro de dispersión en el intervalo  $(1, 3)$  produce percentiles de orden 10 que difícilmente superan el valor de 1 décima. Esto supone una rigidez que no se espera solucionar utilizando una distribución de error distinta. Una posible solución puede ser la definición de un nivel de lluvia apreciable superior a 1 décima y el ajuste de distribuciones Gamma desplazadas.
- En el futuro se ha de valorar la mejora que puede suponer la construcción de modelos específicos para algunas épocas del año en las que la lluvia responde a situaciones características, como ocurre en esta región en el Verano y en el caso del observatorio de Tortosa en Otoño.

# Capítulo 4

## Modelos condicionales de previsión

### 4.1 Introducción

La previsión meteorológica a corto plazo es una de las cuestiones que más interés suscita y el tema al que mayor esfuerzo de personal y medios técnicos dedica el Instituto Nacional de Meteorología.

En este capítulo nos proponemos adaptar el modelo estadístico de lluvia diaria desarrollado en el capítulo anterior para que proporcione una previsión de la precipitación en el día  $t$  utilizando la información meteorológica medida en el propio observatorio hasta las 18 horas del día  $t - 1$ . Se va a ajustar un modelo que estime la probabilidad de precipitación en cada día; a partir de ella y comparando con un umbral, se establecerá la previsión de ocurrencia. Para predecir la cantidad de precipitación se ajustará un modelo con error Gamma.

Para valorar la utilidad de las previsiones obtenidas se llevará a cabo una comparación de éstas con las que el INM obtiene, en condiciones análogas, utilizando el modelo numérico HIRLAM del Centro Europeo de Predicción a corto y medio plazo.

El capítulo comienza con una breve exposición del esquema que se sigue en el INM para realizar la predicción de la precipitación y comentando algunos procedimientos de carácter estadístico que pueden facilitar esa previsión. En la sección 4.3 se presentan los modelos para la predicción diaria ajustados en el aeropuerto de Zaragoza. En la sección 4.4 se analiza la calidad predictiva del modelo HIRLAM que se compara con la del modelo estadístico. En la

sección 4.5 se establecen las conclusiones y señalan las líneas abiertas en las que continuará nuestro trabajo en este campo.

## 4.2 La predicción de la precipitación

### 4.2.1 La predicción en el INM

La previsión meteorológica en el INM proporciona estimaciones de los valores de numerosas variables, temperatura, humedad, vientos y altura en distintos niveles geopotenciales, así como la presión y precipitación en superficie. Para distintos horizontes temporales, que pueden llegar hasta varios días, se tienen previsiones que reflejan cuál será el estado atmosférico sobre una región; estas previsiones se actualizan periódicamente introduciendo nueva información en las ejecuciones de los modelos numéricos. La metodología para establecer la previsión se basa en tres elementos:

- Los modelos que implementan las leyes físicas que rigen la evolución de la atmósfera, capaces de, a partir de la información de satélites, radiosondeos y las medidas registradas en una red hemisférica de observatorios, simular el desplazamiento y evolución a corto y medio plazo de las situaciones sinópticas observadas. Estos modelos proporcionan los valores previstos de las variables atmosféricas en los puntos de una red.
- Los mapas sinópticos generados con las salidas de los modelos plantean la situación atmosférica prevista para distintos horizontes temporales. Los campos de variables en distintas alturas de la troposfera permiten establecer las situaciones sinópticas esenciales a partir de las que se elaboran las previsiones a corto y medio plazo.
- El conocimiento de las características geoclimáticas regionales y la experiencia de los meteorólogos que realizan la predicción es indispensable para interpretar los mapas y predecir los efectos que la situación prevista puede tener en un área concreta. Con los elementos anteriores, el personal del INM predice, en el caso de la precipitación, la cantidad de lluvia, indicando si ésta se encontrará en uno de los intervalos definidos por los valores 0.1 litros/m<sup>2</sup>, 1 l/m<sup>2</sup>, 5 l/m<sup>2</sup>, 10 l/m<sup>2</sup> o si existe riesgo de fuertes precipitaciones.

La última fase de este procedimiento corresponde a una decisión basada en un criterio subjetivo, dependiente del conocimiento del predictor. Éstos

deben reconocer la asociación entre la lluvia y distintas variables, útiles para realizar la predicción a escala local. En el valle del Ebro, por ejemplo, el viento es una variable muy importante: hay vientos, como los de procedencia Suroeste en La Rioja, que anticipan con regularidad y una antelación aproximada de 6 horas la llegada de la lluvia y otros, como el cierzo en Zaragoza, que se dan sistemáticamente tras la ocurrencia de este fenómeno. En este sentido sigue siendo de utilidad la publicación de García de Pedraza (1985) [43], editada por primera vez en 1964, que estudia la predicción de variables de superficie como el viento, la temperatura y la precipitación, así como las relaciones entre estas variables y la situación sinóptica en 500hPa.

### **Modelos numéricos de predicción meteorológica**

Los modelos numéricos de predicción se suelen clasificar en función de su escala espacial y temporal. Atendiendo a la escala espacial pueden ser globales, si abarcan todo el globo terráqueo, o de resolución menor: baja, si es superior a 100 Km, o alta, si se encuentra entre 100 y 10 Km. En cuanto a la escala temporal, los modelos se denominan climáticos, si tienen un horizonte de predicción de varios años, estacionales si su horizonte es de uno a seis meses, de medio plazo, si el horizonte es de 3 a 10 días, de corto plazo, si es de 1 a 2 días, o de muy corto plazo, cuando el horizonte está entre 3 y 24 horas.

Los modelos numéricos proporcionan la predicción a través de la simulación de la evolución atmosférica que se basa en la resolución de sistemas de ecuaciones que representan las leyes físicas que rigen los cambios en los distintos campos atmosféricos. El procedimiento consta de las siguientes etapas:

- Asimilación de los datos observados o fase de definición del estado inicial.

El estado inicial debe ser conocido de la forma más precisa posible, ya que un pequeño error en su especificación será amplificado por el modelo en el pronóstico. Para ello se realiza un análisis de la evolución de los campos iniciales y se contrastan las desviaciones que se observan con la evolución real de la atmósfera; tras introducir las correcciones necesarias, si son precisas, se define el estado inicial de los distintos campos.

- Discretización o fase de resolución numérica de las ecuaciones.

El comportamiento de la atmósfera se describe mediante ecuaciones diferenciales en derivadas parciales no lineales que no tienen solución

analítica, por lo que se resuelven usando técnicas numéricas que proporcionan una solución aproximada en una red de puntos.

- Parametrización o fase de downscaling.

Debido a las aproximaciones necesarias para resolver el sistema de ecuaciones, el modelo establece la previsión en la escala usada en la discretización. Para establecer ésta en una escala más pequeña, se requiere un paso adicional en el que se incorporan a las ecuaciones nuevos términos que tienen en cuenta los efectos influyentes en la escala que se pretende resolver.

### **El modelo numérico HIRLAM**

El Centro Europeo para Predicción a Medio Plazo, con acrónimo ECMWF (European Centre for Medium-Range Weather Forecast), es un organismo internacional financiado por 22 países europeos que tiene como objetivos esenciales: 1) La construcción de modelos dinámicos de la atmósfera para producir predicciones a medio plazo; 2) la preparación de las bases de datos necesarias para alcanzar el objetivo anterior, lo que implica tareas de recogida y almacenamiento de medidas de distintas fuentes: observatorios, boyas, radiosondeos, etc.

El Centro Europeo dispone para realizar la previsión a corto y medio plazo del modelo HIRLAM (High Resolution Limited Area Modelling) que proporciona simulaciones, en distintas escalas espaciales, de la situación atmosférica sobre una zona que comprende toda Europa. Este modelo de predicción numérica se encuentra activo desde 1995 y es mantenido y actualizado regularmente. A partir de los resultados de HIRLAM, el procedimiento operativo para realizar la predicción en cada país, lo desarrolla el instituto nacional correspondiente.

El INM utiliza el modelo HIRLAM para obtener predicciones de los campos correspondientes a tres áreas distintas, denominadas OPR, HIR y CAN, que recubren, respectivamente, Europa, la Península Ibérica y las Islas Canarias, ver figura 4.1. El área OPR corresponde a la ventana comprendida entre las latitudes  $15.5^{\circ}\text{N}$  y  $65.0^{\circ}\text{N}$  y las longitudes  $66.5^{\circ}\text{W}$  y  $30.0^{\circ}\text{E}$  y su resolución es de  $0.5^{\circ}\times 0.5^{\circ}$ . Las otras dos áreas tienen una resolución  $0.2^{\circ}\times 0.2^{\circ}$ , lo que significa celdas de tamaño 17 Km (longitud)  $\times$  21 Km (latitud), aproximadamente. El ámbito de HIR es la ventana  $30.2^{\circ}\text{-}50.0^{\circ}\text{N}$  y  $23.6^{\circ}\text{W}\text{-}15.0^{\circ}\text{E}$  y el de CAN la comprendida entre los  $20.2^{\circ}\text{N}$  y los  $40.0^{\circ}\text{N}$  y las longitudes  $38.6^{\circ}\text{W}$  a  $0.0^{\circ}\text{E}$ .

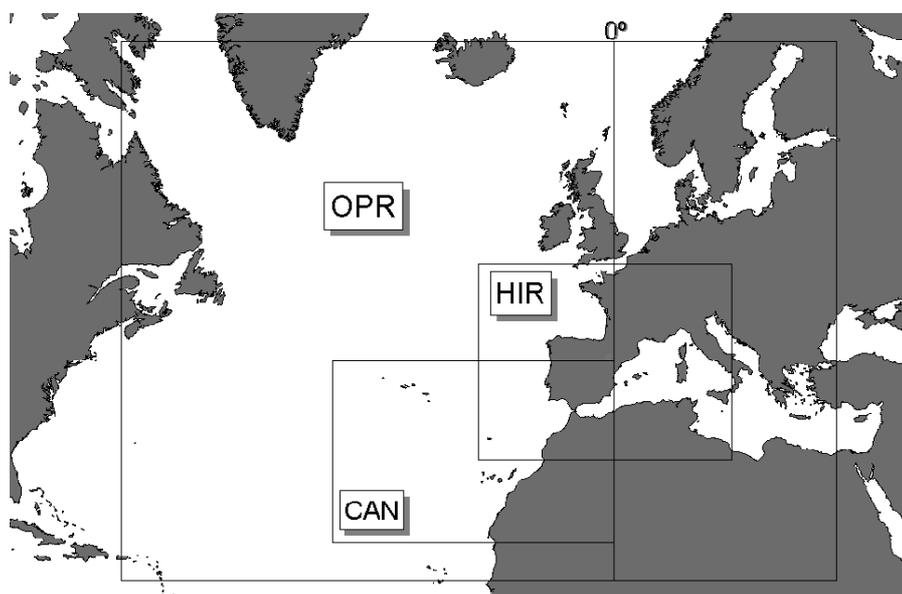


Figura 4.1: Áreas OPR, HIR y CAN del modelo numérico HIRLAM.

Para las tres áreas, el modelo se corre 4 veces al día, obteniéndose resultados para las horas  $h = 0, 6, 12$  y  $18$ . El modelo utiliza la información registrada hasta 3 horas antes y proporciona previsiones para los horizontes:  $h + 6$ ,  $h + 12$ ,  $h + 18$ ,  $h + 24$ ; en la resolución OPR, también para  $h + 48$ .

Para la resolución OPR, las condiciones de contorno vienen dadas por las predicciones del modelo IFS (Integrated Forecast System), un modelo global también del ECMWF con una resolución horizontal  $1.5^\circ \times 1.5^\circ$  y 60 niveles de resolución vertical. Para las áreas HIR y CAN, las condiciones de contorno vienen dadas por las predicciones del área OPR.

Para la inicialización del modelo se emplean las predicciones a seis horas del propio modelo, obtenidas en la pasada anterior; el proceso de asimilación se realiza a partir de los campos de altura geopotencial, componentes de viento y humedad relativa entre las  $h - 3$  y las  $h + 2$  horas.

El modelo predice la presión en superficie, la temperatura, componentes de viento y humedad específica en diversos niveles geopotenciales, desde 1000hPa hasta 200hPa, y obtiene la precipitación como una variable derivada de las anteriores. El operativo predictivo desarrollado por el INM consiste en un procedimiento de parametrización que reduce la escala espacial de los resultados mediante la superposición de un modelo numérico capaz de tener en cuenta los efectos orográficos, fenómenos de convección, etc.

## 4.2.2 Métodos estadísticos de predicción

Como se ha señalado, a partir de la salida del modelo numérico el experto predice las consecuencias en la zona de su responsabilidad. Con el fin de facilitar esta tarea se han usado métodos estadísticos que tratan de cuantificar la probabilidad de precipitación y prever la ocurrencia de fuertes precipitaciones.

El INM ha desarrollado un procedimiento de previsión de la lluvia con un horizonte de 24 y de 48 horas, Del Hoyo y otros (2002) [35], denominado PAP-INM (Predicción Analógica de la Precipitación), operativo desde Octubre de 1999, que estima la probabilidad de que la precipitación total en un día tome valores en alguna de las clases definidas por los umbrales: 0.5, 2, 10 ó 20 litros por metro cuadrado. El sistema predice para los puntos medios de una retícula  $0.5^\circ \times 0.5^\circ$  y también en 88 localidades de la Península y Baleares. El método se basa en la búsqueda de situaciones análogas a la propuesta por HIRLAM en los campos de las alturas geopotenciales 500 y 1000hPa, así como de la humedad relativa media en la capa comprendida entre los 700 y los 1000hPa. El sistema busca, en un banco de datos, los 30 días más parecidos al día problema y calcula la probabilidad de que se produzca precipitación superior a un umbral dado, a partir de las frecuencias relativas observadas en los días considerados análogos.

Otra línea de trabajo en la que se han realizado esfuerzos, se centra en obtener una clasificación de las situaciones climáticas tipo. Se han establecido distintas clasificaciones para las situaciones habituales en la Península Ibérica. La Dirección General del INM publicó una monografía, Sánchez (1993) [102], que establece una clasificación basada en 15 tipos, atendiendo a la posición relativa, respecto a la Península, de anticiclones y depresiones. Goodess (2000) [50], teniendo como objetivo la construcción de un modelo estocástico para la precipitación diaria en el Sureste de España, estableció que la clasificación desarrollada por Lamb para caracterizar las situaciones sobre las Islas Británicas, era válida para la representación de los estados atmosféricos dominantes en la Península. Romero y otros (1999) [101] han construido una clasificación basada en los campos de los niveles geopotenciales 500 y 925hPa, que establece y caracteriza 19 situaciones distintas ligadas al comportamiento de la lluvia en el arco mediterráneo español. Ribalaygua y otros (1996) [96] desarrollaron una clasificación con una finalidad predictiva para la precipitación: a partir de los datos diarios del periodo 1961-1990 en observatorios de la Península y Baleares, establecieron 18 patrones de distribución espacial de la lluvia, que caracterizaron según la situación media

de los campos de alturas geopotenciales 850, 700, 500 y 200hPa, la presión a nivel del mar, el viento en 850 y 250hPa y la temperatura en 850 y 700hPa.

De especial interés es el trabajo de Serrano y otros (1999) [104], que posteriormente tendremos en cuenta para definir una partición del año en épocas diferenciadas, en el que definen 7 modos de clima que ayudan a explicar la distribución espacial de la lluvia en las regiones peninsulares según la época del año. A partir de la precipitación mensual observada durante 74 años en 40 observatorios, identificaron para cada mes las componentes principales que explican la mayor parte de la variabilidad de las series; sobre las 89 componentes extraídas se aplicó un análisis cluster. Los 7 conglomerados resultantes fueron asociados con mapas que describen la situación sinóptica. Su mayor o menor frecuencia explica el régimen de lluvia, puesto que la presencia de cada una de estas situaciones lleva asociada la ocurrencia o ausencia de precipitación en las distintas zonas peninsulares.

Tanto el método operativo del INM como los métodos basados en patrones de circulación requieren la simulación de los modelos numéricos. Alternativamente, se pueden utilizar métodos estadísticos basados en la información meteorológica observada hasta un momento determinado. En esta línea, Armengot y otros (2001) [15] propusieron un método para prever la ocurrencia de lluvias intensas en la Comunidad Valenciana que se basa en la situación de los campos geopotenciales a 850, 700, 500 y 300hPa sobre el Mediterráneo occidental. El procedimiento utiliza un modelo de regresión logística ajustado con los datos de 575 días en los que se observaron condiciones atmosféricas de riesgo, de los que, en 102, se produjeron precipitaciones intensas.

Los modelos propuestos en la sección siguiente operan también a partir de datos observados y tratan de predecir la lluvia en el día  $t$  utilizando la información registrada en el propio observatorio hasta las 18 horas del día  $t - 1$ .

### 4.3 Modelos de previsión de la precipitación

En esta sección se presentan modelos estadísticos que intentan prever la precipitación que se registrará en el aeropuerto de Zaragoza entre las 0 y las 24 horas. El objetivo es analizar la capacidad predictiva a corto plazo de una adaptación del modelo estadístico desarrollado en el capítulo anterior, que utilizará la información disponible hasta las 18 horas del día previo, hora-tipo en la que se registra la última información meteorológica en superficie.

La construcción del modelo ha seguido los criterios descritos en las subsecciones 3.3.1 y 3.7.2. Las covariables utilizadas son las disponibles para el modelo *CM sondeos* de Zaragoza, ver sección 3.7.1 y tabla 3.14, observadas en los días anteriores al que se hace la predicción; de no mencionarlo expresamente, las covariables se refieren al día  $t - 1$ . Para valorar la capacidad predictiva de los modelos se han empleado, debidamente adaptadas, las herramientas de crítica utilizadas en el capítulo 3. Los datos usados para la estimación son los del periodo 1990-1997 y los reservados para validación los de los años 1998 a 2000.

En la siguiente subsección se presenta un modelo que predice la ocurrencia en cualquier día del año. Se han ensayado también, con el objetivo de analizar si resultan más simples e interpretables y prevén mejor, modelos específicos para aquellas épocas en las que los especialistas indican que existen situaciones atmosféricas generadoras distintas. Los resultados obtenidos, así como la comparación con el modelo anual, se muestran en la subsección 4.3.2. En la subsección 4.3.3 se valora la utilidad de un modelo predictivo de la cantidad recogida.

#### 4.3.1 Modelo de previsión de ocurrencia

El modelo anual para predecir la ocurrencia se describe en la tabla B.1. Lo más destacable de él es la presencia de numerosos efectos asociados a la dirección del viento en superficie a las 12 horas.

Los términos del modelo que no interaccionan con el viento en superficie son los armónicos, el efecto lineal de la última medida de humedad y el de la presión en superficie a las 18h, ver figura 4.2. Entre las variables de altura es significativo el punto de rocío en 700hPa correspondiente al último radiosondeo.

El cambio de presión entre las dos últimas mediciones tiene un efecto decreciente y lineal, con un término cuadrático cuando el viento es NW en

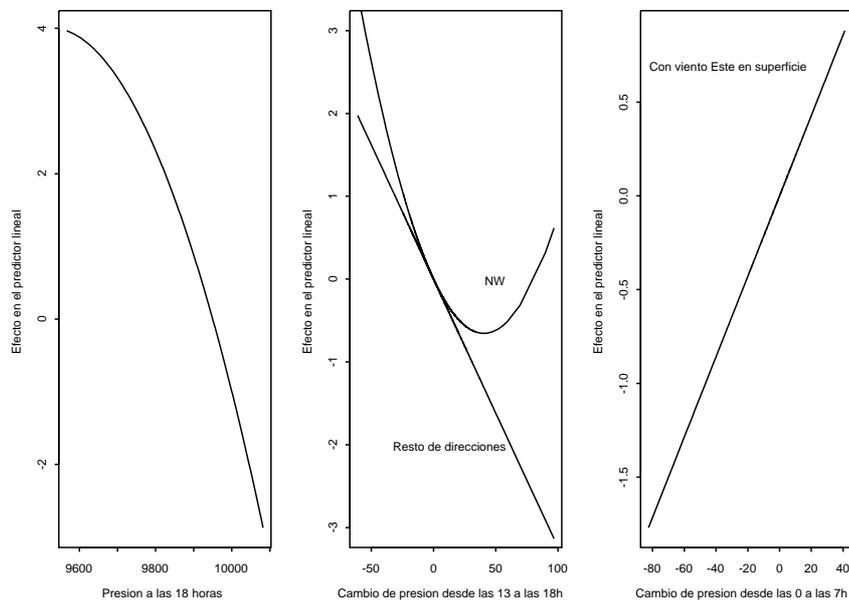


Figura 4.2: Efecto de la presión atmosférica en el modelo de previsión de ocurrencia. De izda. a dcha.: Efecto de la presión a las 18 horas, del cambio de presión entre las 13 y las 18h y del cambio de presión entre las 0 y las 7h.

superficie, ver figura 4.2. En presencia de viento del Este, el efecto del cambio de presión en las dos primeras medidas del día  $t-1$  y de la humedad registrada a las 7 horas resultan significativos, lo que supone una mayor memoria que la de otras situaciones.

El efecto de la dirección del viento en la altura geopotencial 500hPa en interacción con su dirección en superficie, se muestra en la figura 4.3. Las situaciones que corresponden a un flujo en altura de procedencia Sur y Suroeste están asociadas con un efecto positivo; la presencia de viento SW en superficie, ligado generalmente a una situación de baja térmica en el interior de la Península, y de viento SE en altura provoca el mayor incremento en el predictor lineal. El efecto positivo asociado al viento Este en superficie combinado con una dirección SW en altura ( $200^\circ$ ) es menor.

La velocidad del viento en superficie tiene un coeficiente negativo, así como la velocidad en 500hPa cuando en superficie hay viento de Norte, lo que se justifica porque los vientos fuertes en Zaragoza suelen ser de procedencia NW, ver figura 3.28, y están provocados por una situación anticiclónica que se desplaza desde el Oeste hacia el Valle. La velocidad en 500hPa tiene un

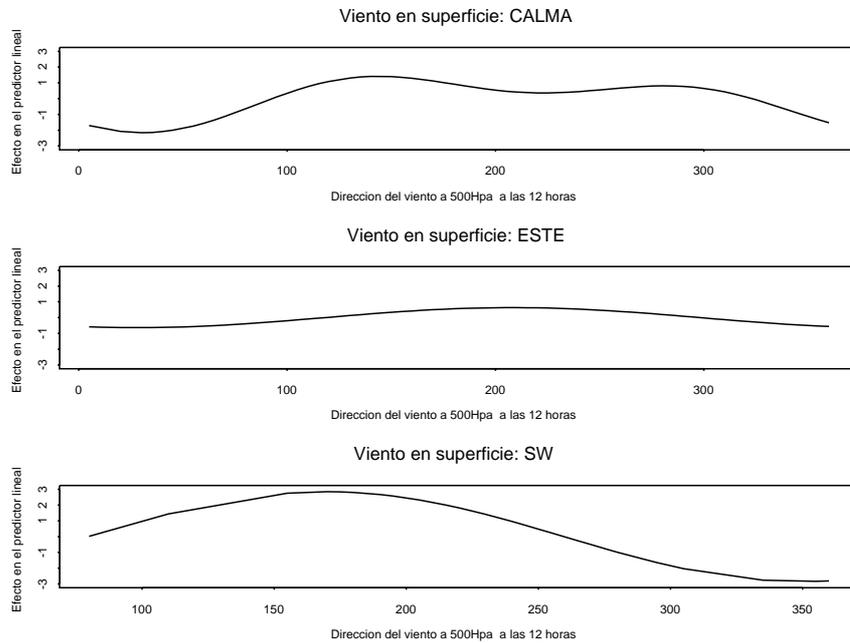


Figura 4.3: Efecto de la dirección del viento en 500hPa a las 12h.

efecto positivo cuando sopla NW en superficie.

Al comparar este modelo predictivo con el equivalente ajustado en el capítulo anterior, ver tabla A.60, destaca que:

- El modelo contemporáneo tiene menos términos que, en general, presentan mayores valores del estadístico  $t$ .
- La información del viento, tanto en altura como en superficie, tiene un papel relevante desde el punto de vista predictivo.
- La ausencia de información contemporánea hace que el efecto de las covariables retardadas no sea el mismo en ambos modelos. Las covariables de humedad en el día previo, por ejemplo, tienen un efecto positivo en el modelo de previsión y negativo en el modelo contemporáneo, en presencia de información de humedad del día  $t$ .

En la tabla B.2 se muestran las medidas de bondad de ajuste de este modelo de previsión. La variabilidad explicada, globalmente, es un 21.6% y, por estaciones, se reduce hasta un 13.5% en el Verano, valores que son bastante inferiores a los de *CM sondeos* que explicaba, globalmente, un 49% de la variabilidad. En la figura 4.4 se aprecia que las frecuencias mensuales están adecuadamente representadas; el coeficiente de correlación asociado al

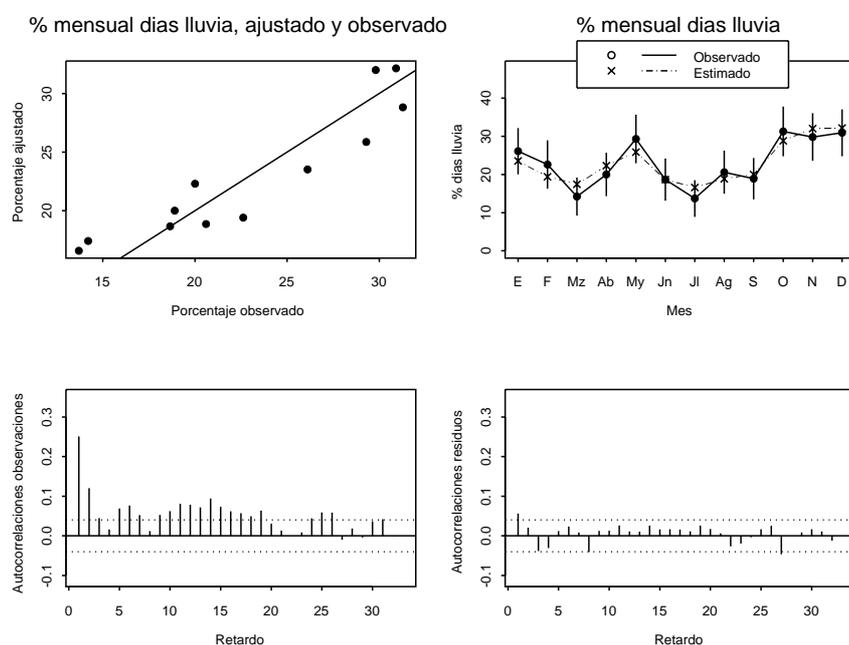


Figura 4.4: Comportamiento del modelo de previsión de ocurrencia (1990-1997).

diagrama de frecuencias relativas observadas frente a ajustadas es 0.92. A diferencia de lo que ocurría en los modelos del capítulo anterior, la autocorrelación residual de orden 1 es significativa, ver figura 4.4, aunque su valor, 0.06, es mucho menor que el correspondiente en la serie de observaciones, 0.25.

Respecto al comportamiento predictivo del modelo cabe señalar:

- Si se usa el umbral 0.5 para establecer la previsión:
  1. El porcentaje de días bien predichos ronda un 80%, tanto global como estacionalmente. Esto supone una reducción de un 7% frente al porcentaje de días bien clasificados con *CM sondeos* y, estacionalmente, reducciones entre un 1% en Invierno y un 8.7% en Otoño.
  2. En la circunstancia más difícil de predecir, la de cambio de estado seco a húmedo, se obtiene un 20.3% de éxitos, frente a un 53.7% con *CM sondeos*.
  3. El porcentaje de aciertos %*NAS* es mínimo en Verano, 12.5%, cuando en *CM sondeos* era un 46.7%.
- Utilizando la frecuencia relativa de lluvia como umbral:

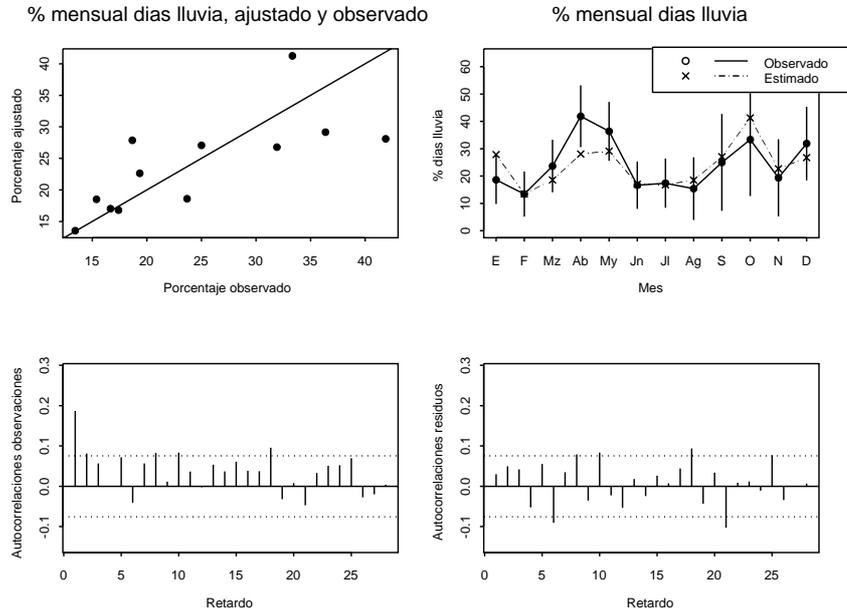


Figura 4.5: Comportamiento del modelo de previsión de ocurrencia, periodo de validación (1998-2000).

1. El porcentaje de días bien predichos, un 69.9% globalmente, es menor que el obtenido con el umbral 0.5, particularmente en Verano. La situación peor predicha corresponde al inicio de racha seca; en las otras tres se alcanza un nivel de éxito aceptable.
2. El porcentaje  $\%NAS$  disminuye en Verano y toma valores semejantes en las demás estaciones. Salvo en Invierno, este porcentaje mejora el obtenido con el otro umbral.
3. El porcentaje de días bien predichos es un 17% menor que el de bien clasificados con *CM sondeos*, disminución que se observa en los porcentajes estacionales. La reducción es menor en los días húmedos que siguen a otro húmedo.

### Comportamiento del modelo en el periodo de validación

En la tabla B.3 se indican las medidas que permiten valorar el ajuste del modelo en el conjunto de validación. La variabilidad explicada disminuye a un 15%, destacando las reducciones que se producen en Primavera y Otoño. En la figura 4.5 se observa que algunas de las frecuencias medias mensuales ajustadas difieren de las observadas, lo que se refleja en un coeficiente de correlación de 0.72.

Al analizar el cambio que se produce en las medidas de los dos periodos, se observa que la degradación de este modelo de predicción es mayor que la de *CM sondeos*, ver tablas A.66 y A.77. El porcentaje de variabilidad explicada se reducía un 2% en aquél, mientras que en el de previsión se reduce en un 6.5%. En este modelo, el porcentaje de días bien predichos cuando se usa el umbral 0.5 desciende un 12% en Primavera, cuando la mayor disminución estacional en *CM sondeos* era un 4%.

En cuanto a las cualidades predictivas, los resultados globales son semejantes a los obtenidos en el periodo de ajuste. Se producen reducciones notables para el umbral 0.5 en los inicios de racha húmeda pero no se detectan cambios con el umbral de la frecuencia observada. En conclusión, sobre el periodo de validación, que corresponde a una situación equivalente al uso operativo del modelo, y utilizando la frecuencia relativa como umbral, se obtiene un índice global de previsiones correctas del 70% y, en los días húmedos, un valor que supera el 50%.

### 4.3.2 Modelos de previsión de ocurrencia por épocas del año

La precipitación, durante el Invierno, la Primavera y el Otoño, está asociada, por lo general, con perturbaciones atmosféricas de escala sinóptica y con el movimiento general de la circulación que va del Atlántico hacia el Este. En el Verano la lluvia está ligada a situaciones mucho más locales: fenómenos convectivos debidos al calentamiento, al contenido de humedad en la atmósfera y a la inestabilidad en las capas altas.

La distribución de las situaciones atmosféricas que provocan precipitación en la Península Ibérica varía según la época del año. El trabajo citado de Serrano y otros (1999) [104] indica la existencia de 7 situaciones sinópticas que explican el comportamiento de la precipitación. El modo climático que denominan Atlántico es el que produce precipitación en una zona más amplia y se observa entre los meses de Noviembre a Marzo, cuando la circulación atmosférica favorece que los frentes atraviesen la Península. De Abril a Octubre, sin embargo, el desplazamiento del frente polar hacia el Norte hace que las borrascas se muevan por latitudes mayores y que, por lo tanto, no afecten con la misma frecuencia a la Península. Sólo dos de esas 7 situaciones, que los autores denominan Portugal y Cantábrico, influyen en los meses más cálidos.

Teniendo en cuenta este comportamiento decidimos construir modelos de

previsión distintos según las épocas. Su interés radica en la posibilidad de construir modelos más simples e interpretables, que pueden predecir mejor y donde figuren los efectos relevantes que representen las situaciones que ocurren en esa época del año y pueden ser poco frecuentes en el resto.

Asesorados por meteorólogos del Centro Territorial del INM en Zaragoza, se definieron 3 épocas:

- Fría, que incluye los meses de Noviembre a Marzo, ambos inclusive.
- Cálida, que comprende el intervalo desde el 16 de Junio hasta el 15 de Septiembre, ambos inclusive.
- Templada, que comprende el resto de los días, es decir, la Primavera y el Otoño, estaciones en las que la lluvia es más frecuente y abundante.

El modelo correspondiente a cada época se ha construido partiendo del modelo estimado para todo el año, en el que se realiza un proceso de eliminación de los términos no significativos cuando se aplica a los datos de cada época. Posteriormente se lleva a cabo una fase de introducción de predictores en la que se estudia la significación de todas las covariables no incluidas en ese momento en el modelo, siguiendo la estrategia comentada en las subsecciones 3.3.1 y 3.7.2. Se ha optado por este procedimiento para facilitar la obtención de predictores comparables.

Se presentan a continuación los aspectos más relevantes de los modelos ajustados en cada época.

### Meses fríos

La tabla B.4 contiene los 12 términos que componen el predictor lineal del modelo ajustado. En él aparecen algunos de los efectos más significativos del modelo anual, con un coeficiente semejante en el caso de las covariables  $z.\Delta P.18.13_{t-1}$ ,  $z.H18_{t-1}$  y  $z.R700.12_{t-1}$ . Permanece también el efecto de la última presión registrada en superficie,  $P18_{t-1}$ , que sigue siendo decreciente, aunque ahora sólo aparece su término lineal, y se mantienen algunos efectos asociados a las interacciones con la dirección del viento en superficie; con viento del SW, el efecto de  $dV500.12_{t-1}$  concuerda con el del modelo anual.

Los términos propios de este modelo son la temperatura en 850hPa y, en presencia de viento Este en superficie, la diferencia entre la temperatura en 850 y 500hPa.

La tabla B.5 contiene las medidas de bondad de ajuste correspondientes al periodo de estimación. El porcentaje de variabilidad explicada es ligeramente menor al obtenido con el modelo anual en Invierno, un 22.3% frente a un 26%.

En la tabla B.6 aparecen los resultados de la valoración del modelo en el periodo de validación, donde explica un 18.6% de la variabilidad. Encontramos discrepancias importantes en los porcentajes de días con precipitación observados y previstos por meses, que se reflejan en un coeficiente de correlación 0.33. Esto es debido en buena parte a que el mes de Marzo tiene mayor frecuencia de días de lluvia en este periodo, 23 días, que en el de estimación, 14 días, un cambio que no ha sido bien ajustado.

### Capacidad predictiva

Con el objetivo de comparar la capacidad predictiva, en la tabla 4.1 se muestran los porcentajes de días bien predichos por el modelo específico y, entre paréntesis, los porcentajes del modelo anual cuando se aplica a los días de esta época. Además del porcentaje global y de  $\%NAS$ , aparecen los valores correspondientes a las distintas situaciones de  $Y_t$  e  $Y_{t-1}$  con los que se ha calculado un valor medio, denotado  $\overline{\%Y_t : Y_{t-1}}$ , como medida global del grado de éxito en la previsión.

Utilizando el umbral 0.5 para establecer la previsión:

- Los días correctamente predichos por el modelo específico en el periodo de estimación son, globalmente, un 78.7% un valor inferior al del modelo anual que produce mayores porcentajes de acierto en los días húmedos, un 8% y un 11% más, de modo que el porcentaje  $\%NAS$ , un 36.2%, es claramente superior al del modelo específico.
- En el periodo de validación el modelo anual predice mejor los días húmedos y peor la llegada de una racha seca, de modo que los dos modelos tienen el mismo valor de  $\overline{\%Y_t : Y_{t-1}}$ . El porcentaje de predicción correcta de los días de lluvia es menor que en el periodo de estimación, y llega a ser inferior al 50% en los días húmedos precedidos de otro húmedo.

Con el umbral de la frecuencia relativa:

- En el periodo de estimación, los porcentajes de días bien predichos por el modelo específico son similares o mayores que los obtenidos con el modelo anual.

Periodo de estimación						
Global	$Y_t = 0$ $Y_{t-1} = 0$	$Y_t = 0$ $Y_{t-1} = 1$	$Y_t = 1$ $Y_{t-1} = 0$	$Y_t = 1$ $Y_{t-1} = 1$	$\frac{\%Y_t : Y_{t-1}}$	$\%NAS$
Umbral 0.5						
78.7 (80.2)	97.3 (96.0)	77.0 (74.8)	19.4 (30.7)	54.1 (62.2)	62.0 (65.9)	29.2 (36.2)
Umbral frec. día						
73.2 (70.8)	80.8 (78.9)	39.6 (33.1)	60.4 (58.4)	90.1 (89.2)	67.7 (64.9)	41.0 (38.3)
Periodo de validación						
Umbral 0.5						
81.4 (79.7)	98.0 (95.1)	90.6 (81.3)	10.5 (18.4)	41.7 (45.8)	60.2 (60.2)	20.3 (23.1)
Umbral frec. día						
75.3 (77.4)	82.2 (84.2)	40.6 (43.8)	63.2 (65.8)	83.3 (83.3)	67.3 (69.3)	37.6 (40.2)

Tabla 4.1: Porcentajes de días bien predichos por el modelo para los meses fríos. Para cada resultado, entre paréntesis, se muestra el correspondiente porcentaje obtenido con el modelo anual aplicado a los mismos días.

- La predicción en el periodo de validación es mejor con el modelo anual. Tanto el porcentaje global como  $\%NAS$  y el valor de  $\frac{\%Y_t : Y_{t-1}}$  superan en un 2%, aproximadamente, los valores del modelo específico. En la situación peor prevista por el modelo anual, el inicio de racha seca, se alcanza un 43.8% de éxitos y en el resto de situaciones definidas por  $Y_t$  e  $Y_{t-1}$  se supera el 65%.

En síntesis, el modelo para la época fría resulta más simple pero no proporciona un ajuste mejor de los datos de estimación. En el conjunto de validación, el porcentaje de variabilidad explicada se degrada de manera análoga a como lo hacía en el modelo anual. En cuanto al objetivo de predicción, los resultados no señalan una mejora generalizada respecto al modelo anual.

### Meses templados

En la tabla B.7 se presenta la composición del predictor lineal del modelo ajustado, que tiene 16 parámetros. La mayoría de ellos corresponden a covariables incluidas en el modelo anual: el cambio en la presión de las 13 a las 18 horas, el efecto cuadrático de la última presión registrada, la humedad en superficie a las 18 horas y el punto de rocío a 700hPa, en estos dos últimos casos con un coeficiente próximo en ambos modelos. En la época templada

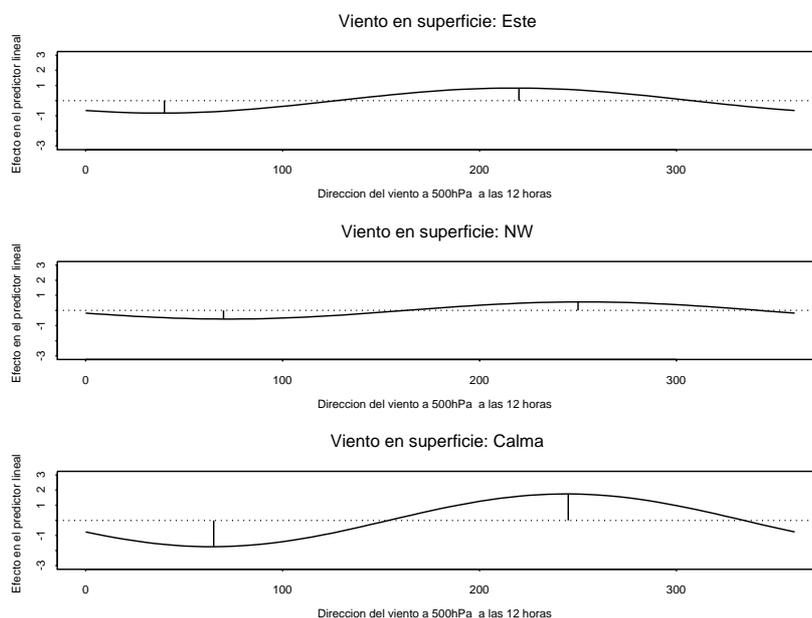


Figura 4.6: Efecto de la dirección del viento en 500hPa a las 12h en el modelo para los meses templados.

se incorpora nueva información relativa a la última temperatura registrada en superficie, que tiene un efecto negativo.

Ésta es la única época en la que aparece el efecto del cambio de presión entre las dos primeras horas-tipo y el de la humedad a las 7 horas, si existe viento Este en superficie, predictores significativos también en el modelo anual. Debido a la presencia de estas covariables, el modelo requiere información de las 24 horas previas, a diferencia de los modelos de las otras épocas, donde todas las covariables relevantes corresponden a medidas hechas a partir de las 12 horas.

Cuando la dirección del viento en superficie es NW o hay calma, la dirección en 500hPa que produce mayor incremento en la probabilidad de lluvia es SW ( $245^\circ$ ), ver figura 4.6; con viento Este en superficie, la dirección en 500hPa más favorable a la lluvia tiene procedencia Sur-Suroeste.

La tabla B.8 contiene las medidas de bondad de ajuste de este modelo. Se obtiene un porcentaje de variabilidad explicada de un 25%, que es semejante al del modelo anual en Primavera (27%) y superior al de Otoño (17%).

El comportamiento de este modelo en el periodo de validación, ver tabla

Periodo de estimación						
Global	$Y_t = 0$ $Y_{t-1} = 0$	$Y_t = 0$ $Y_{t-1} = 1$	$Y_t = 1$ $Y_{t-1} = 0$	$Y_t = 1$ $Y_{t-1} = 1$	$\frac{Y_t}{Y_{t-1}}$	%NAS
Umbral 0.5						
79.3 (79.3)	95.5 (97.4)	78.0 (79.8)	24.0 (18.3)	57.3 (52.1)	63.7 (61.9)	32.5 (29.4)
Umbral frec. día						
73.2 (74.0)	81.0 (81.3)	37.6 (45.0)	65.4 (60.6)	82.3 (84.4)	66.6 (67.8)	40.6 (40.9)
Periodo de validación						
Umbral 0.5						
72.2 (69.4)	91.8 (96.3)	80.6 (77.8)	25.0 (15.0)	56.8 (40.5)	63.6 (57.4)	33.3 (23.6)
Umbral frec. día						
67.7 (64.4)	68.2 (78.0)	55.6 (33.3)	60.0 (45.0)	86.5 (75.7)	67.6 (58.0)	43.8 (36.8)

Tabla 4.2: Porcentajes de días bien predichos por los dos modelos de previsión en los días del periodo templado.

B.9, muestra que la variabilidad explicada se reduce hasta el 16.5%, un valor superior a los obtenidos con el modelo anual, 12.7% en Primavera y 6.9% en Otoño.

#### Capacidad predictiva

En la tabla 4.2 se comparan los porcentajes de días bien previstos con este modelo y con el modelo anual aplicado a los datos de este periodo.

Cuando se utiliza el umbral 0.5 los hechos destacables son:

- En el periodo de estimación, el porcentaje de días bien predichos globalmente es un 79.3% con ambos modelos. El modelo específico consigue mejores resultados en los días lluviosos, un 6% suplementario.
- En el periodo de validación, los porcentajes de días bien predichos con el modelo anual disminuyen respecto a los del periodo de estimación: el porcentaje para días iniciales de racha húmeda, por ejemplo, queda en un 15%. Por el contrario, los resultados con el modelo de los meses templados no presentan cambios.

En este periodo, el modelo específico proporciona valores similares o mejores que el modelo anual; en particular en los días húmedos mejora el porcentaje de días bien previstos en, al menos, un 10%.

Usando la frecuencia relativa como umbral:

- En el periodo de estimación, con el modelo específico se alcanza, globalmente, un 73.2% de días bien predichos, siendo la peor situación la de comienzo de racha seca. El porcentaje global de días bien clasificados, el  $\%NAS$  y el valor de  $\overline{\%Y_t:Y_{t-1}}$  son ligeramente menores, en este modelo, que los correspondientes del modelo anual.
- En el periodo de validación y con el modelo específico, se reduce hasta un 68.2% el porcentaje de días bien predichos en los que son secos y precedidos de uno seco. Cabe señalar que con el modelo específico se supera el 50% de aciertos en las cuatro situaciones definidas por  $Y_t$  e  $Y_{t-1}$ .
- En el periodo de validación, los porcentajes global,  $\%NAS$  y  $\overline{\%Y_t:Y_{t-1}}$  son mejores con este modelo que con el anual.

De todo ello concluimos que el modelo de previsión reproduce las características generales de la precipitación en los meses con temperatura suave, de manera semejante al modelo anual. Aspectos a favor del modelo específico son que el predictor lineal es más sencillo y que, aunque no produce mejoras sustanciales en las medidas de bondad de ajuste, cuando se aplica a los datos de validación la variabilidad explicada se reduce menos que en el modelo anual. Finalmente cabe resaltar que el modelo específico tiene mayor capacidad predictiva con cualquiera de los dos umbrales y que, con el umbral de la frecuencia relativa, se supera el 55% de aciertos en las cuatro situaciones dadas por  $Y_t$  e  $Y_{t-1}$ .

### Meses cálidos

En la tabla B.10 se presenta el ajuste del modelo correspondiente al periodo cálido del año que requiere sólo 9 parámetros. Las características de la precipitación en esta estación hacen que exista poca información útil para predecir la ocurrencia de lluvia en el día siguiente. Al compararlo con el modelo anual vemos que se mantienen el efecto lineal de la presión a las 18 horas, el punto de rocío a 700hPa y, a diferencia de los modelos de las otras dos épocas, la velocidad del viento en superficie.

La existencia de viento de procedencia Este en superficie hace que el efecto de  $vV500.12_{t-1}$  sea negativo. El efecto de  $dV500.12_{t-1}$  en combinación con viento Este en superficie, indica que el mayor incremento de la probabilidad se asocia con la dirección  $220^\circ$  y la mayor disminución con la de  $40^\circ$ ; la formación de cúmulos en los Pirineos que descienden hacia zonas más bajas del

Valle, empujadas por vientos en altura de dirección NE, no suelen atravesar la sierra de Guara y no producen lluvia en Zaragoza.

Resulta influyente la variable que mide el grado de humedad en la troposfera media,  $R700.12_{t-1}$ , un efecto que aparece en todos los modelos y que refleja la presencia de una situación nubosa en esa altura asociada a algún frente que, junto con el bochorno del día siguiente, puede provocar lluvia. No interviene en este modelo  $H18_{t-1}$ , última medida de humedad disponible en superficie; pensamos que ésta es una variable que puede favorecer la ocurrencia de tormenta en el día  $t - 1$  pero cuyo efecto no alcanza al día  $t$ , dado el proceso de renovación atmosférica producido por el movimiento del aire en superficie.

La misma explicación cabe para el efecto negativo, aparentemente extraño, de la variable  $T18_{t-1}$  en presencia de viento Este. En Verano, una alta temperatura a las 18 horas favorece la precipitación tormentosa en el día  $t - 1$ , lo que supone, en el caso de que se produzca, que el ambiente se refresca y, por tanto, una menor probabilidad de ocurrencia en el día  $t$ .

Los meteorólogos utilizan distintos índices para medir el riesgo de tormentas, por ejemplo el índice K usado para caracterizar situaciones con fuertes precipitaciones en Valencia por Armengot y otros (2001) [15]. En el predictor lineal del modelo para los meses cálidos se ha incluido una variable indicadora del riesgo de tormenta, definida a partir de variables medidas en 850hPa y 500hPa:

$$torm00.520_{t-1} = \begin{cases} 1 & \text{si } 2 \times T850.00_{t-1} - R850.00_{t-1} - 2 \times T500.00_{t-1} > 520 \\ 0 & \text{en otro caso.} \end{cases}$$

Esta combinación de variables describe de manera global el estado térmico e hídrico de la atmósfera:

- $T850.00_{t-1} - T500.00_{t-1}$  mide la diferencia de temperatura entre esas capas,
- $T850.00_{t-1} - R850.00_{t-1} - T500.00_{t-1}$  puede interpretarse como una medida del estado de humedad entre esas dos alturas.

En la predicción meteorológica cuando este índice es mayor que 520 se considera probable la ocurrencia de lluvia y si es superior a 550 la ocurrencia de fuertes precipitaciones. En el modelo se ha utilizado la variable indicadora del umbral 520.

Periodo de estimación						
Global	$Y_t = 0$ $Y_{t-1}=0$	$Y_t = 0$ $Y_{t-1}=1$	$Y_t = 1$ $Y_{t-1}=0$	$Y_t = 1$ $Y_{t-1}=1$	$\frac{Y_t}{Y_{t-1}}$	%NAS
Umbral 0.5						
84.5 (83.2)	99.0 (99.5)	93.2 (91.9)	7.0 (1.6)	32.3 (25.7)	57.9 (54.7)	14.6 (9.4)
Umbral frec. día						
67.3 (62.6)	69.4 (64.7)	42.4 (32.3)	64.9 (67.2)	93.6 (82.9)	67.6 (61.8)	27.6 (25.2)
Periodo de validación						
Umbral 0.5						
83.1 (84.4)	99.1 (100)	88.2 (100)	9.1 (0)	20.0 (20.0)	54.1 (55.0)	10.0 (4.0)
Umbral frec. día						
66.9 (63.0)	69.8 (66.7)	41.2 (22.2)	63.6 (70.0)	100 (100)	68.7 (64.7)	26.4 (25.0)

Tabla 4.3: Porcentajes de días bien predichos por los dos modelos de previsión en los días del periodo cálido.

La tabla B.11 muestra que el modelo de previsión en los meses cálidos tiene un comportamiento peor que los de las otras dos épocas, con un porcentaje de variabilidad explicada de 15.8%, ligeramente superior al 13.4% del modelo anual en Verano.

La tabla B.12 contiene las medidas de calidad de ajuste en el periodo 1998-2000. La escasa variabilidad explicada, un 4.7%, refleja la dificultad de construir un modelo de previsión en estos meses; el modelo anual explica algo más de variabilidad, un 7.2%, lo que representa un menor descenso respecto al periodo de estimación.

### Capacidad predictiva

La tabla 4.3 permite comparar la capacidad predictiva del modelo ajustado con la del modelo anual aplicado a los días de este periodo.

Cuando se utiliza el umbral 0.5:

- En el periodo de estimación el modelo específico alcanza un 84.5% de días con previsión correcta. Este valor se obtiene con la clasificación correcta de los días secos en un 99% y un 93% de las ocasiones, dependiendo de lo ocurrido en el día previo, y acertando sólo un 7% de

los días iniciales de racha húmeda. El modelo anual tiene este mismo problema.

- En el periodo de validación el cambio más importante aparece en los días húmedos precedidos de uno húmedo, donde el modelo sólo acierta en un 20% de los casos. El modelo anual no es útil para establecer la previsión en los meses cálidos, ya que estos problemas se agravan, como pone de manifiesto el porcentaje nulo de aciertos en la predicción del inicio de racha húmeda.

Utilizando como criterio de clasificación la frecuencia diaria:

- En el periodo de estimación, las predicciones son mejores con el modelo específico. Se predicen correctamente más de la mitad de los días en tres de las situaciones dadas por  $Y_t$  y por  $Y_{t-1}$ , aunque se alcanza sólo un 69% de éxito en los días secos precedidos de otro seco y un 41% en los días iniciales de racha seca.
- En el periodo de validación, la predicción de los días secos con el modelo anual es más deficiente, predice bien sólo un 22% de los días iniciales de racha seca; el nivel de éxito es equivalente o algo mejor en los días húmedos por lo que produce valores del porcentaje global y  $\frac{\%Y_t:Y_{t-1}}$  sólo un 4% menores que el modelo específico.

En síntesis, el modelo para esta época del año no mejora de un modo apreciable la variabilidad explicada respecto del modelo anual y sufre incluso una reducción mayor en la variabilidad explicada en el periodo de validación. Respecto a su utilidad predictiva, con el umbral de la frecuencia relativa proporciona en el periodo de validación resultados que no son sistemáticamente mejores que los del modelo anual, con el que se obtiene peor predicción del inicio de racha seca y mejor del de racha húmeda.

### Comparación general entre los modelos

En este apartado se comparan brevemente los cuatro modelos de previsión ajustados, se analizan sus predictores lineales, la variabilidad explicada y se valoran los cambios en la capacidad predictiva que provoca el uso de los dos umbrales.

En la tabla 4.4 se muestran las covariables con un efecto significativo en alguno de los cuatro modelos; para aquéllas que aparecen en dos o más se indica, con fines comparativos, el valor del coeficiente estimado. En el caso

de la dirección del viento en 500hPa se señala, en cada modelo, cuál es la dirección que aporta mayor efecto positivo al predictor lineal.

Observamos en la tabla que la presión en superficie a las 18 horas y el punto de rocío en el geopotencial 700hPa a las 12h son efectos comunes a todos los modelos, que tienen un carácter decreciente y valor comparable. Por el contrario, las variables espesor de la capa 850-500hPa y diferencia de presiones en superficie al inicio de los días  $t - 1$  y  $t - 2$ , sólo tienen efecto significativo en el modelo anual.

La temperatura en superficie a las 18 horas es significativa en tres de los modelos y, en el de los meses fríos, la temperatura en 850hPa a las 12 horas. Cabe señalar que la diferencia de temperaturas entre los geopotenciales 850 y 500hPa, una de las variables de mayor interés para los meteorólogos en el momento de predecir la precipitación, no tiene efecto significativo en los meses templados ni en el anual.

El comportamiento del viento es una información relevante que aparece en todos los modelos a través de su velocidad y dirección en superficie así como en 500hPa. Salvo en el modelo para los meses fríos, la presencia de viento Este en superficie junto con la de viento de SW ( $205-220^\circ$ ) en altura conlleva un incremento de probabilidad de ocurrencia; existe también un efecto favorable ligado al viento SW en superficie y SE ( $170^\circ$ ) en 500hPa. En todos los casos, las direcciones de máximo efecto en el geopotencial 500hPa corresponden a procedencias entre el Sur y el Oeste, de  $140^\circ$  a  $270^\circ$ .

En el periodo de estimación, la variabilidad explicada por los modelos específicos es baja en todos los casos, en especial en los meses cálidos, y de un valor similar al obtenido con el modelo anual en las estaciones correspondientes, ver tabla 4.5. En el periodo de validación, el modelo de los meses templados explica más variabilidad que el anual en Primavera y Otoño, lo que no ocurre en los meses cálidos y fríos.

En la tabla 4.6 se muestran los porcentajes de días bien predichos por los distintos modelos, con el objeto de establecer conclusiones sobre la predicción usando ambos umbrales y para identificar las situaciones y épocas con peor previsión. De su análisis se extraen las siguientes conclusiones:

- En el periodo de validación se obtienen porcentajes semejantes a los que se alcanzan en el de estimación, de modo que puede considerarse que la calidad de los modelos es la misma en ambos periodos. Los valores de  $\overline{\%Y_t : Y_{t-1}}$  varían entre 0.1% y un 4% con el umbral 0.5 y

	Anual	Fríos	Templados	Cálidos
Armónicos	2	1	0	0
$P18_{t-1}$	$0.42x - 0.000022x^2$ Decr.	$-0.0076x$	$1.71x - 0.000088x^2$ Decr.	$-0.011x$
$\Delta P.18.13_{t-1}$	-0.032 Cuadr.(NW)	-0.038 Cuadr.(NW)	-0.043	
$P00_{t-1} - P00_{t-2}$	Crec.(Calma)			
$\Delta P.7.0_{t-1}$	0.021 (E)		0.036 (E)	
$H18_{t-1}$	0.015	0.015	0.017	
$H07_{t-1}$	0.030 (E)		0.05 (E)	
$T18_{t-1}$	-0.0094 (E)		-0.0083 -0.0030 (SW)	-0.0110 (E)
$vV SUP.12_{t-1}$	-0.037			-0.152
$vV500.12_{t-1}$	-0.036 (N) 0.014 (NW)			-0.035 (E)
$dV500.12_{t-1}$ (dirección de efecto máximo)	140°, 270° (Calma) 210° (E) 170° (SW)	170° (SW)	245° (Calma) 205° (E) 250° (NW)	220° (E)
$R700.12_{t-1}$	-0.0028	-0.0028	-0.0028	-0.0047
$A85/50.12_{t-1}$	Crec.			
$T850.12_{t-1}$		Decr.		
$T85/50.12_{t-1}$		Crec. (E)		
$torm00.520_{t-1}$				Crec. (E)

Tabla 4.4: Comparación de los términos significativos en los modelos de previsión de ocurrencia. Se indica entre paréntesis la dirección de procedencia del viento en superficie en cuya presencia el efecto es significativo.

Modelo	Estimación	Validación
Anual	21.6	15.1
Fría	22.3	18.6
Anual en Invierno	26.0	21.9
Templada	25.2	16.5
Anual en Primavera	27.0	12.7
Anual en Otoño	17.0	6.9
Cálida	15.8	4.7
Anual en Verano	13.5	7.2

Tabla 4.5: Porcentajes de variabilidad explicada por los distintos modelos de previsión.

Periodo de estimación							
Umbral 0.5							
Modelo	Global	$Y_t = 0$ $Y_{t-1} = 0$	$Y_t = 0$ $Y_{t-1} = 1$	$Y_t = 1$ $Y_{t-1} = 0$	$Y_t = 1$ $Y_{t-1} = 1$	$\frac{Y_t}{Y_{t-1}}$	%NAS
Anual	80.6	97.4	80.0	20.3	52.9	62.7	29.3
Fríos	78.7	97.3	77.0	19.4	54.1	62.0	29.2
Templados	79.3	95.5	78.0	24.0	57.3	63.7	32.5
Cálidos	84.5	99.0	93.2	7.0	32.3	57.9	14.6
Umbral frec. día							
Anual	69.9	75.8	37.1	61.0	86.4	65.1	35.7
Fríos	73.2	80.8	39.6	60.4	90.1	67.7	41.0
Templados	73.2	81.0	37.6	65.4	82.3	66.6	40.6
Cálidos	67.3	69.4	42.4	64.9	93.6	67.6	27.6

Periodo de validación							
Umbral 0.5							
Modelo	Global	$Y_t = 0$ $Y_{t-1} = 0$	$Y_t = 0$ $Y_{t-1} = 1$	$Y_t = 1$ $Y_{t-1} = 0$	$Y_t = 1$ $Y_{t-1} = 1$	$\frac{Y_t}{Y_{t-1}}$	%NAS
Anual	77.4	96.7	83.7	13.3	40.9	58.7	20.8
Fríos	81.4	98.0	90.6	10.5	41.7	60.2	20.3
Templados	72.2	91.8	80.6	25.0	56.8	63.6	33.3
Cálidos	83.1	99.1	88.2	9.1	20.0	54.1	10.0
Umbral frec. día							
Anual	69.8	78.0	34.9	58.2	80.3	62.9	35.1
Fríos	75.3 (77.4)	82.2 (84.2)	40.6 (43.8)	63.2 (65.8)	83.3 (83.3)	67.3 (69.3)	37.6 (40.2)
Templados	67.7 (64.4)	68.2 (78.0)	55.6 (33.3)	60.0 (45.0)	86.5 (75.7)	67.6 (58.0)	43.8 (36.8)
Cálidos	66.9 (63.0)	69.8 (66.7)	41.2 (22.2)	63.6 (70.0)	100 (100)	68.7 (64.7)	26.4 (25.0)

Tabla 4.6: Porcentajes de días bien predichos por los modelos. En el periodo de validación se muestra, entre paréntesis, el porcentaje correspondiente obtenido con el modelo anual en los días de ese periodo.

entre un -2% y un +1% con el de la frecuencia de lluvia.

Con el umbral 0.5 cabe destacar la disminución del porcentaje de éxito que se observa en los días húmedos precedidos de uno húmedo y la mejora que se obtiene en el modelo para los meses fríos al predecir los días iniciales de racha seca. Con el otro umbral los cambios más notables se encuentran en el modelo para los meses templados, donde destaca el incremento en los primeros días de racha seca (+18%) y el descenso en los días secos que siguen a uno seco (-13%).

- El umbral 0.5 produce altos porcentajes de días bien predichos globalmente. Al desglosar según la ocurrencia en los días  $t$  y  $t-1$ , observamos que la situación peor prevista es la llegada de una racha húmeda, donde a lo sumo alcanza un 25% de aciertos. En los cuatro modelos ajustados, el porcentaje de bien predichos es superior al 90%, cercano incluso al 100%, en los días secos precedidos de uno seco y es elevado en los días iniciales de racha seca. Así, en los meses cálidos se consigue el mayor porcentaje de éxitos global y en los días secos, tanto en el periodo de estimación como en el de validación, y simultáneamente se obtiene el menor valor de  $\overline{\%Y_t : Y_{t-1}}$  y del porcentaje  $\%NAS$ .

Se concluye finalmente que este umbral es poco adecuado porque obtiene altos resultados globales basados en la predicción certera de los días secos pero sus aciertos son escasos en los días húmedos, menos numerosos.

- Con el umbral de la frecuencia relativa, el estado húmedo tiene mayor probabilidad de ser seleccionado como predicho. Por este motivo la situación peor prevista es la de inicio de racha seca. El menor porcentaje de éxito en esa situación es un 34.9% en el modelo anual.

La frecuencia relativa resulta un umbral más adecuado puesto que, pese a producir porcentajes globales de éxito menores, el porcentaje de acierto en las distintas épocas es más homogéneo y no está sobredimensionado por la correcta clasificación de los días secos. Tanto el  $\%NAS$  como la media  $\overline{\%Y_t : Y_{t-1}}$  son mayores con el umbral de la frecuencia relativa que con 0.5 en los cuatro modelos, destacando en particular los meses cálidos.

- Al analizar la capacidad predictiva de los modelos específicos y del anual sobre los datos del periodo de validación, es decir, en una situación equivalente a su uso operativo, y usando el umbral de la frecuencia diaria cabe destacar que:

- En los meses fríos, el modelo anual resulta más adecuado en todas las situaciones y alcanza, con un 69.3%, el mayor valor de  $\overline{\%Y_t : Y_{t-1}}$ .
- En los meses templados el modelo particular es superior al modelo anual en todos los porcentajes salvo en el de los días secos precedidos de uno seco, de modo que el valor de  $\overline{\%Y_t : Y_{t-1}}$  es casi un 10% mayor.
- En los meses cálidos el modelo anual sólo predice bien un 22% de los días iniciales de racha seca pero mejora el porcentaje del modelo específico en los días de inicio de racha húmeda. Así, éste obtiene resultados superiores, en un 4%, globalmente y en  $\overline{\%Y_t : Y_{t-1}}$ , con los que no se puede concluir de forma clara que sea mejor que el anual.

En resumen, señalemos que el modelo ajustado para todo el año contiene la mayor parte de la información relevante a las 18 horas del día previo que requieren los modelos estacionales. De hecho, la construcción de modelos específicos en los meses fríos y cálidos no proporciona mejoras sistemáticas en las medidas de calidad de los ajustes, en particular, en el porcentaje de días bien predichos. El modelo para los meses templados tiene más capacidad predictiva que el modelo anual.

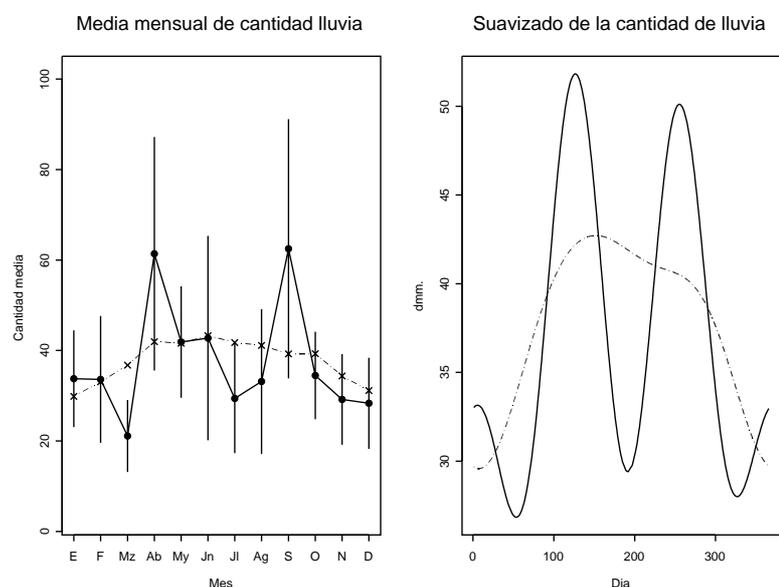


Figura 4.7: Izda.: Cantidad media observada y ajustada, por meses, con el modelo de previsión de cantidad. Dcha.: Suavizado de los valores diarios observados y ajustados.

### 4.3.3 Modelos de previsión de cantidad

Para completar el modelo de previsión se ha ajustado uno con distribución de error Gamma que estima, a partir de la información disponible a las 18 horas del día previo, la cantidad de lluvia recogida en un día de precipitación.

El resultado de este ajuste se muestra en la tabla B.13. A diferencia de los modelos de previsión de la ocurrencia, éste contiene muy pocos términos significativos. La única información relevante a las 18 horas del día previo es la medida de humedad en superficie, que tiene un efecto lineal y positivo, y la presión a las 0 y a las 18 horas, covariables que están entre las significativas en los dos modelos contemporáneos de cantidad ajustados en Zaragoza.

En la tabla B.14 se muestran las medidas de bondad de ajuste de este modelo, muy poco satisfactorio en cuanto a la reproducción de la variabilidad de los datos, un 3.6% de variabilidad explicada, y que presenta diferencias importantes entre las cantidades medias observadas y ajustadas en los meses de Marzo, Abril, Julio y Septiembre, ver figura 4.7.

El comportamiento del modelo en los datos de validación es también muy

pobre, ver tabla B.15. De todo ello se concluye que el modelo ajustado no es útil para la predicción de la cantidad de lluvia.

Como alternativa a esta aproximación nos planteamos el desarrollo en el futuro de modelos que ajusten la probabilidad de que la cantidad registrada supere un determinado nivel de precipitación; es decir, se tratará de desarrollar modelos semejantes al de previsión de ocurrencia, cuya respuesta sea la serie de la variable indicadora de superar un determinado umbral, por ejemplo los valores usados por el INM:  $1 \text{ l/m}^2$ ,  $5 \text{ l/m}^2$  ó  $10 \text{ l/m}^2$ .

## 4.4 Predicción de la precipitación mediante el modelo HIRLAM y comparación con los resultados del modelo estadístico

### 4.4.1 Introducción

Se ha indicado en la sección 4.2 que una previsión de la precipitación es obtenida por el INM de la salida del modelo HIRLAM, que proporciona la predicción de lluvia en el periodo de 24 horas medidas a partir de cuatro horizontes de 6, 12, 18 y 24 horas, respectivamente. Vamos a comparar la previsión con horizonte de 6 horas con la obtenida con los modelos estadísticos ajustados en la sección anterior.

En la siguiente subsección se comparan las características de la lluvia prevista por HIRLAM con las de la lluvia observada, a fin de identificar posibles insuficiencias del modelo. Como veremos que la previsión de cantidad hecha por HIRLAM tampoco es adecuada, en la subsección 4.4.3 compararemos la capacidad de ambos modelos para predecir la ocurrencia de lluvia.

### 4.4.2 Análisis de las predicciones de HIRLAM en Zaragoza

El INM nos ha proporcionado las previsiones de lluvia diaria para Zaragoza obtenidas con HIRLAM en la pasada de las 0 horas, con la resolución HIR y un horizonte de 6 horas, donde el modelo predice la lluvia entre las 6 horas de ese día y las 6 horas del día siguiente.

Se dispone de la lluvia total prevista, que se denota TP, obtenida al sumar la precipitación que provocan los frentes de escala sinóptica, denominada LSP, y la lluvia convectiva, denotada CP. La lluvia LSP la predice el modelo mientras que la lluvia convectiva, generada por procesos de escala local, se obtiene mediante un operativo desarrollado por el INM, que se ha acoplado a HIRLAM.

En primer lugar vamos a valorar la reproducción del régimen de precipitación en Zaragoza que logra ese modelo, considerando, en primer lugar, el comportamiento de la lluvia diaria prevista y atendiendo después a la descomposición habitual: frecuencia de ocurrencia y cantidades recogidas cuando llueve.

El periodo de análisis comprende 1196 días que van de Junio de 1997,

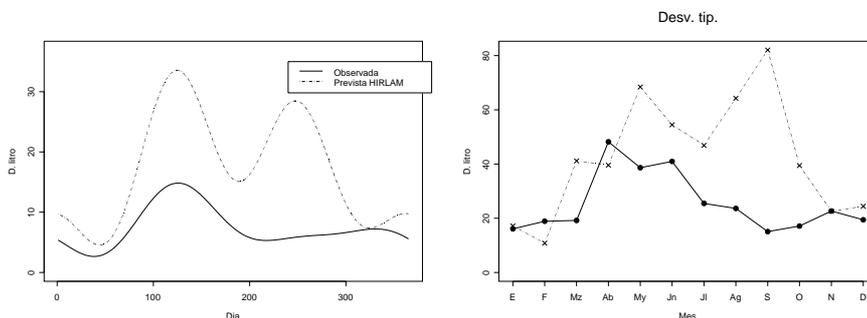


Figura 4.8: Izda.: Valores suavizados de las cantidades diarias observadas y previstas TP por HIRLAM. Dcha.: Desviación típica de esas cantidades, por meses.

cuando comienza la serie de previsiones HIRLAM proporcionada por el INM, a Septiembre de 2000, últimos datos utilizados en el ajuste del modelo estadístico.

### Análisis de la previsión

En la tabla B.16 se comparan, las cantidades observadas y las previstas TP, LSP y CP. Para ello se muestran la media, desviación típica y autocorrelación de primer orden de la secuencia de lluvia diaria, así como la frecuencia relativa de que la lluvia supere los umbrales 0, 10 y 50 décimas de litro, los momentos de las cantidades positivas y, para valorar la persistencia de la lluvia, la frecuencia relativa de día húmedo tras otro húmedo y los momentos de las longitudes de racha seca y húmeda. Las tablas B.17 y B.18 contienen las medidas citadas para cada mes del año.

Los valores de lluvia total prevista por HIRLAM son, en general, muy diferentes de los observados y producen discrepancias apreciables en los estadísticos de posición central y dispersión. La lluvia TP no reproduce el ciclo anual observado en Zaragoza, como puede verse en la figura 4.8. Las discrepancias en el nivel medio son evidentes: el modelo sobreestima la precipitación de este observatorio e indica la existencia de una época húmeda en Primavera, que coincide con la observada, y de otra al inicio del mes de Septiembre, que no existe en Zaragoza.

En la figura 4.8 derecha se muestra, para cada mes, la desviación típica de la lluvia diaria observada y de la prevista TP. La dispersión de esta última es distinta de la observada en los meses de Primavera, Verano y Otoño, particularmente en Septiembre, y similar entre los meses de Noviembre y Febrero, en los que las aportaciones de lluvia CP son de poca entidad.

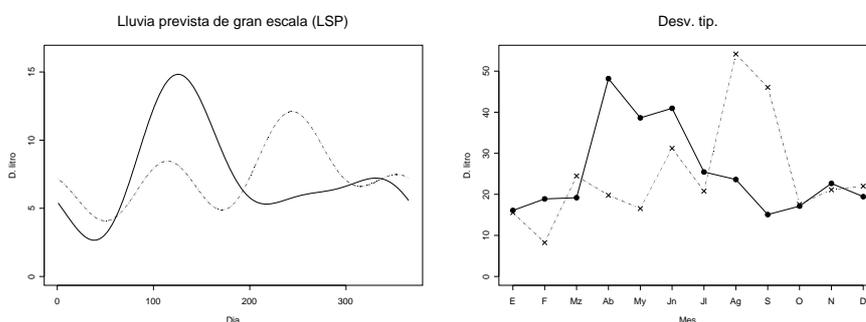


Figura 4.9: Izda.: Valores suavizados de las cantidades diarias observadas y previstas LSP. Dcha.: Desviación típica por meses.

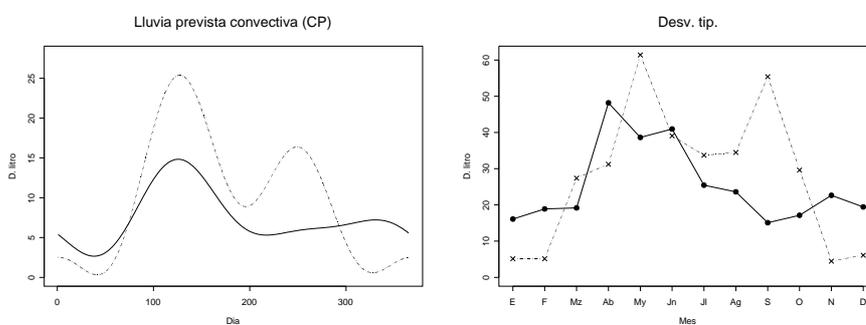


Figura 4.10: Izda.: Valores suavizados de las cantidades diarias observadas y previstas CP. Dcha.: Desviación típica por meses.

En las tablas B.16-B.18 y en las figuras 4.9 y 4.10 se analizan las cantidades previstas de cada tipo de lluvia, convectiva y de gran escala, y se comparan con la lluvia registrada para averiguar si alguna de ellas aisladamente representa mejor, en algún periodo, el comportamiento de la precipitación.

El suavizado de la lluvia prevista LSP tiene un máximo en el mes de Septiembre que explicaría, en parte, las discrepancias entre la lluvia TP y la observada en esa época del año, mientras que, en Primavera, la previsión queda por debajo de la lluvia observada. El valor medio de la previsión LSP es muy semejante al de la lluvia observada en bastantes meses (las diferencias son menores de 2 décimas de litro) salvo en los meses de Abril y Mayo donde suponen la mitad de la media observada y en los de Agosto y Septiembre donde son casi el doble. El esquema temporal de la discrepancia en la desviación típica es similar, ver figura 4.9 derecha.

La previsión CP produce valores medios pequeños, en relación con los observados, en los meses de Noviembre a Febrero, lo que es razonable, y

valores demasiado grandes en los de Mayo, Agosto y Septiembre. La cantidad CP prevista sobrevalora en esos meses la lluvia total que cae sobre Zaragoza.

Si se comparan los datos observados y previstos mediante el coeficiente de correlación, ver tablas B.16-B.18, se observa que, en general, éste toma valores pequeños y que es muy variable; los coeficientes calculados con la lluvia TP sólo son mayores de 0.5 en los meses de Enero, Marzo, Junio y Diciembre. En síntesis, el nivel de las cantidades previstas no corresponde con la lluvia en el aeropuerto de Zaragoza y el modelo HIRLAM no genera una serie de cantidades que respete el orden relativo de la lluvia registrada.

### **Análisis de las cantidades positivas**

Para valorar las previsiones HIRLAM en los días en los que se observa precipitación, se han representado en la figura 4.11 los suavizados de las cantidades observadas y previstas en los días lluviosos observados y la desviación típica en esos días, para cada mes. Los hechos más relevantes son los siguientes:

- El suavizado de la lluvia TP se sitúa en valores similares al de la cantidad observada en los meses de Noviembre y Diciembre y tiene un comportamiento relativamente paralelo al del ciclo observado durante el primer semestre del año. La discrepancia es máxima en Septiembre, mes en el que la desviación típica es muy superior a la observada.
- La previsión LSP presenta un suavizado similar al de las cantidades observadas positivas desde Septiembre hasta Febrero pero es sensiblemente menor en los meses de Primavera y de inicio del Verano, con una discrepancia máxima en los de Mayo y Junio.
- Las cantidades CP muestran un ciclo anual similar al descrito para TP con, lógicamente, valores menores en los meses de Noviembre a Marzo. El nivel del suavizado pone de manifiesto que la parametrización hecha por el INM para esta lluvia no se comporta satisfactoriamente en el territorio que representa Zaragoza.
- Para las dos componentes de la lluvia, la desviación típica de las cantidades previstas es muy superior a la observada en el mes de Septiembre.

Se concluye que durante los meses del periodo frío, de Noviembre a Marzo, las previsiones LSP y TP, ya que CP toma valores despreciables, reproducen adecuadamente el nivel medio de la cantidad de lluvia en los días húmedos observados. En los meses restantes las cantidades propuestas por HIRLAM son inadecuadas.

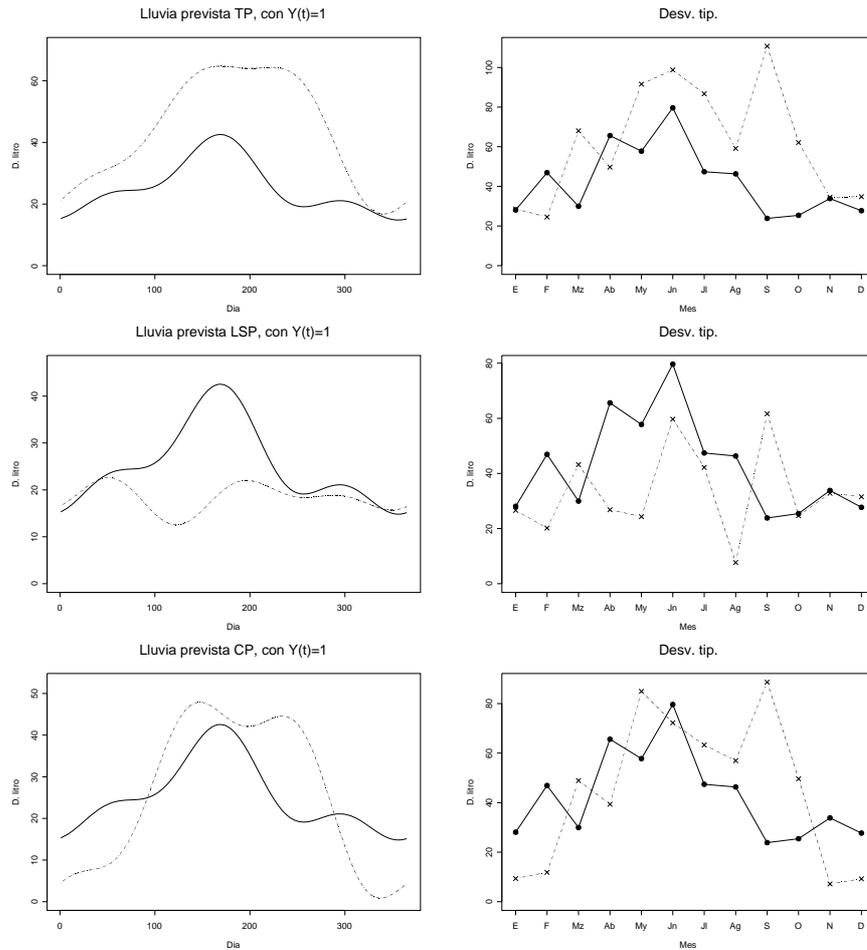


Figura 4.11: Izda.: Valores suavizados de las cantidades diarias observadas y previstas por HIRLAM en los días con precipitación. Dcha.: Desviación típica por meses.

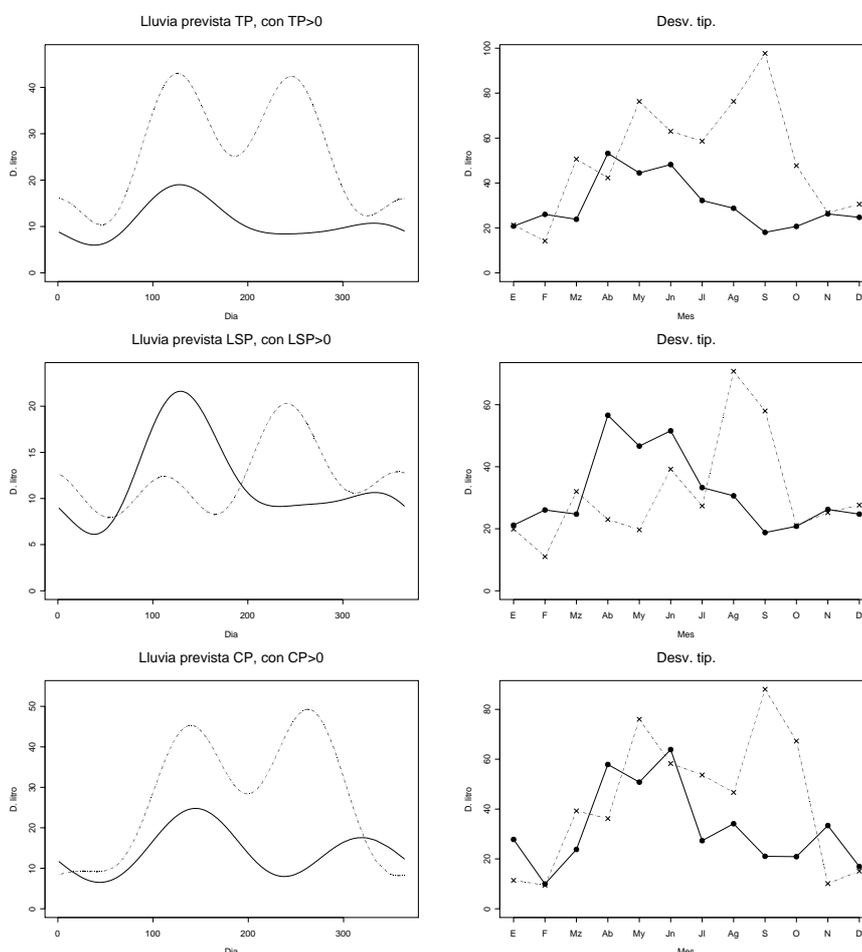


Figura 4.12: Izda.: Valores suavizados de las cantidades diarias observadas y previstas por HIRLAM, cuando éstas son positivas. Dcha.: Desviación típica por meses.

Para complementar el estudio, vamos a analizar el comportamiento de la lluvia observada cuando la previsión es positiva. Para ello se presentan los gráficos que corresponden a los días en los que la lluvia TP es positiva, análogamente para LSP y CP, en la figura 4.12.

El suavizado de las cantidades TP supera al correspondiente a los datos observados, sobre todo en los meses en que hay una mayor aportación de la lluvia CP; ambas previsiones tienen valores máximos en Abril y Agosto que, en el último caso, no existe en el perfil observado. Con la predicción LSP la similitud vista en la figura 4.11 en los meses fríos es ahora menor. En Primavera el suavizado de LSP es menor que el observado, de modo que

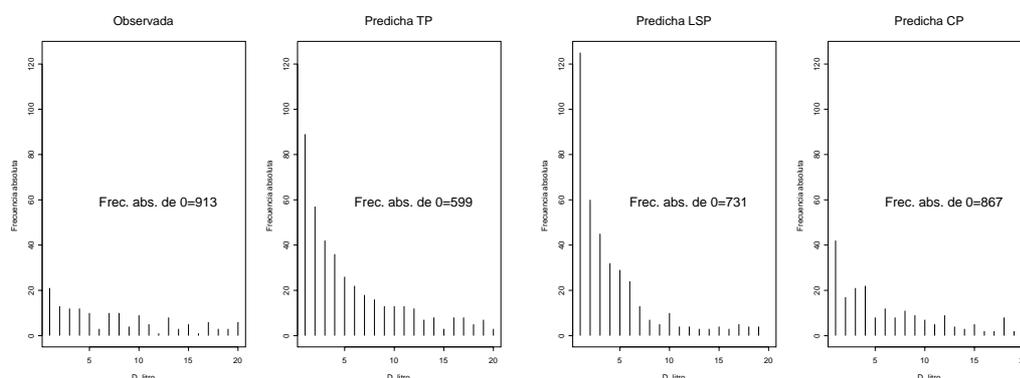


Figura 4.13: Diagramas de barras de las frecuencias absolutas de las cantidades entre 1 y 20 décimas de litro observadas y previstas TP, LSP y CP.

la predicción de la lluvia requiere el aporte complementario de la previsión CP, si ésta fuera adecuada. Entre Julio y Septiembre el nivel de LSP es muy superior al observado, lo que significa un sesgo del modelo HIRLAM que sólo puede agravarse con la adición de CP.

### Análisis de la previsión de ocurrencia de precipitación

Hemos visto que las previsiones de HIRLAM sobreestiman la lluvia en Zaragoza. Esa sobrevaloración, ver figura 4.13, se debe en parte a que el modelo prevé cantidades positivas pequeñas con mayor frecuencia que la observada. La frecuencia de días con precipitación TP, 0.64, es mucho mayor que la frecuencia observada, 0.24, ver tabla B.16. En la figura 4.14 superior izquierda, se muestra que ese sesgo se produce a lo largo de todo el año.

Para analizar si la previsión HIRLAM reproduce la persistencia de la lluvia, se incluye en las tablas B.16-B.18 la frecuencia relativa de que se mantenga el estado húmedo (lluvia apreciable) y la media y la desviación típica de las longitudes de racha, seca y húmeda. Las frecuencias relativas obtenidas a partir del modelo superan a las observadas en la mayor parte de los meses y, en consecuencia, las rachas secas generadas son de menor longitud media que las observadas, mientras en las rachas húmedas se da la situación contraria.

En la figura 4.13 es apreciable la discrepancia existente en las frecuencias de las cantidades pequeñas. Para verificar si utilizando umbrales superiores a 1dl las previsiones tienen un comportamiento más correcto, en la figura 4.14 aparecen los suavizados de la frecuencia relativa diaria de las cantidades observadas y previstas TP, mayores o iguales a 5, 10 y 15 décimas de litro.

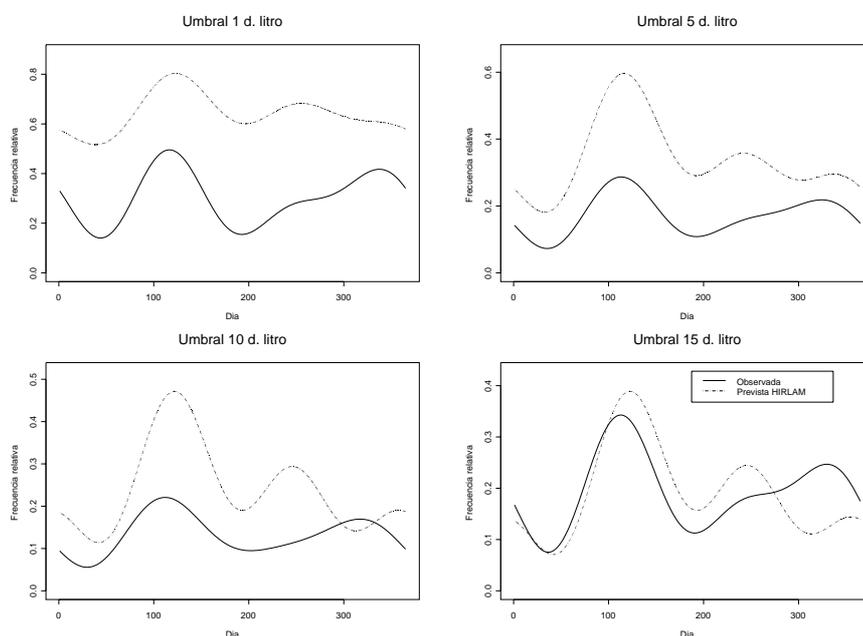


Figura 4.14: Suavizado de las frecuencia relativa de lluvia diaria superior a los umbrales especificados, observada y prevista TP por HIRLAM.

Podemos concluir que:

- Las frecuencias observadas no se corresponden con las obtenidas de la predicción de lluvia TP para ninguno de los umbrales. Con 1 y 5dl la previsión de HIRLAM supera a los valores observados, incluso los duplican en algunas épocas.

Con 15dl la frecuencia de HIRLAM es similar a la observada durante la mayor parte del año: coincide en los tres primeros meses y tiene un perfil paralelo, ligeramente superior, entre Abril y Agosto. Los suavizados se separan en los tres últimos meses del año.

- Las frecuencias relativas que produce HIRLAM tienen un máximo en los meses de Primavera con los cuatro umbrales; la otra época de máximo relativo, que se localiza alrededor de Noviembre en las frecuencias observadas, está desplazada hacia Septiembre en los suavizados de la previsión HIRLAM.

En las figuras 4.15 y 4.16 se muestran los suavizados de las frecuencias relativas, observadas y previstas LSP y CP, en los días en que éstas son mayores o iguales a 1, 3, 5 y 10 décimas de litro. Cabe destacar que:

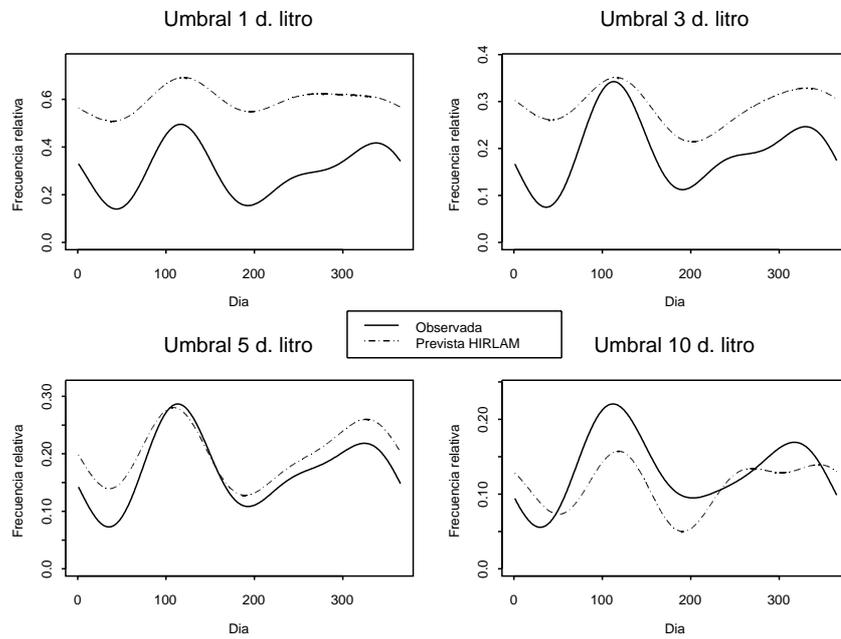


Figura 4.15: Suavizado de la frecuencia relativa de lluvia diaria, observada y prevista LSP, superior a los umbrales especificados.

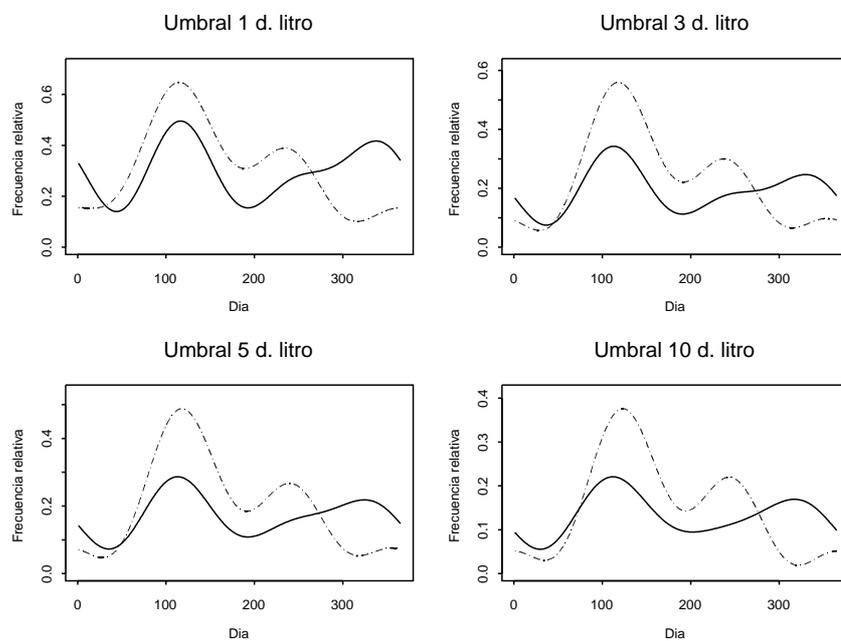


Figura 4.16: Suavizado de la frecuencia relativa de lluvia diaria, observada y prevista CP, superior a los umbrales especificados.

- Existe una buena correspondencia entre el perfil suavizado de la frecuencia de lluvia LSP y la observada con el umbral 5 décimas de litro: los suavizados coinciden entre Abril y Junio y en el resto del año presentan una evolución paralela.
- Con los cuatro umbrales, los suavizados de la previsión CP superan a los de las observaciones en los meses con actividad convectiva.

Recapitulando los análisis efectuados, la predicción de cantidades con HIRLAM no es correcta para el área representada por el observatorio de Zaragoza. Esto es consecuencia, por una parte, de que el modelo convectivo produce cantidades cuya media diaria es muy superior a la observada en los meses con ese tipo de actividad y, por otra, a que la previsión LSP muestra un incremento en el nivel medio alrededor del mes de Septiembre que sobrevalora el nivel observado.

#### **4.4.3 Comparación entre las previsiones de ocurrencia del modelo estadístico y las procedentes de HIRLAM**

Se ha mostrado en la sección 4.3 que sólo el modelo estadístico de previsión de ocurrencia tiene alguna utilidad. En esta subsección se pretende comparar dicha predicción con la de HIRLAM, considerando que éste predice un día húmedo si la cantidad TP es mayor o igual que 1 décima de litro. Como se ha visto que las cantidades HIRLAM sobreestiman las observadas y, en particular, la frecuencia de días con lluvia poco importante, posteriormente se obtendrá a partir de HIRLAM una nueva predicción de ocurrencia ajustando el umbral para declarar la ocurrencia de lluvia.

Los modelos estadísticos ajustados proporcionan la probabilidad de ocurrencia de lluvia entre las 0 y las 24 horas de un día, a partir de la información disponible a las 18 horas del día previo, es decir, también con un horizonte de 6 horas. Para determinar la predicción se utilizará el umbral de la frecuencia relativa diaria.

En la comparación se utilizan únicamente los 820 días, que van desde Junio de 1997 a Julio de 2000, para los que se dispone de predicciones con los dos modelos. El 81% de esos días no ha sido utilizado para la estimación de los modelos estadísticos, por lo que se puede considerar que éstos no tienen una ventaja apreciable.

En primer lugar se compara la predicción del modelo estadístico anual con la obtenida a partir de las cantidades TP, declarando un día lluvioso cuando TP es positiva. A continuación, teniendo en cuenta que en la subsección anterior se ha encontrado que la lluvia LSP tiene un comportamiento semejante a las cantidades observadas durante la época fría, ver figura 4.9, se incluyen los resultados obtenidos cuando se usa esa lluvia. Además, en las diferentes épocas del año definidas, se comparan las previsiones de los modelos estadísticos considerados mejores: el anual en la época fría, el específico en la templada y ambos modelos en la cálida.

En la tabla B.19 se compara la predicción obtenida por el modelo estadístico anual y la de HIRLAM. La tabla contiene algunas características agregadas, como la frecuencia relativa de días con lluvia y la frecuencia relativa condicionada a lo observado en el día previo. Se ha calculado el coeficiente de correlación entre los indicadores binarios de ocurrencia, observado y asociado a la previsión.

En esa tabla destaca el buen ajuste, por parte del modelo estadístico, de las cinco proporciones evaluadas y los valores excesivos que propone la predicción HIRLAM. Las proporciones de éxito en la previsión también favorecen al modelo estadístico, tanto globalmente (al menos un 10% más) como por estaciones y según el estado de la ocurrencia de lluvia en el día previsto y en el anterior, salvo en las situaciones correspondientes a ocurrencia de día húmedo.

En las tablas B.20 a B.22 se muestran los resultados correspondientes a las tres épocas que se han diferenciado. El análisis de la capacidad predictiva de los modelos en esas épocas da lugar a conclusiones semejantes:

- El porcentaje global de éxitos es superior en los modelos estadísticos, al menos en un 10%, respecto al obtenido a partir de TP.
- La mayor frecuencia de cantidades TP positivas hace que los porcentajes de días húmedos bien predichos sean superiores a los obtenidos con los modelos estadísticos, sobre todo en el comienzo de racha húmeda; a pesar de ello el valor de  $\overline{\%Y_t : Y_{t-1}}$  es ligeramente superior en estos modelos.

Los resultados obtenidos con las cantidades LSP son similares a los de TP cuando se usan todos los datos y algo mejores en la época fría, sin llegar a superar al modelo estadístico.

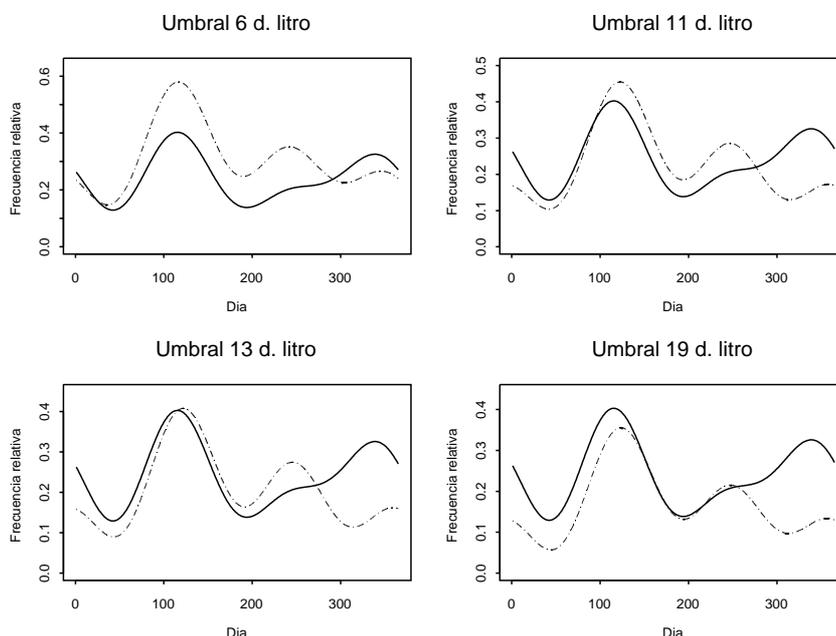


Figura 4.17: Suavizado de la frecuencia relativa de ocurrencia de lluvia observada y de lluvia TP igual o superior a los umbrales especificados.

### Uso de la predicción HIRLAM con otro umbral

Para ensayar una solución a las consecuencias que tiene el sesgo de HIRLAM relativo al excesivo número de días predichos húmedos, hemos decidido ajustar el umbral que determina la previsión de ocurrencia. Con este fin se ha buscado aproximar la proporción observada de días húmedos con la proporción de días en que HIRLAM prevé una lluvia superior o igual al umbral a seleccionar.

En la figura 4.17 pueden verse los suavizados de la frecuencia relativa observada y de que TP sea mayor o igual que los umbrales que se indican. No hay ningún umbral para el que exista una correspondencia a lo largo de todo el año entre ambas curvas; sin embargo, al considerar épocas diferenciadas vemos la similitud entre el suavizado de la frecuencia de lluvia observada y el correspondiente al umbral 6 décimas de litro para los meses fríos, 19dl para los cálidos y 13dl para los meses templados, aunque en el Otoño es imposible acoplar los dos suavizados con ningún umbral.

Las tablas B.23, B.24 y B.25 tienen una estructura análoga a las B.19-B.22 y contienen los resultados obtenidos definiendo día húmedo a partir de estos nuevos umbrales. Cabe destacar los siguientes hechos:

- Las frecuencias de precipitación observadas están bien aproximadas ahora por las resultantes del uso de HIRLAM.
- Destaca el fuerte incremento del éxito en la predicción obtenido con TP y estos umbrales, en relación con los valores obtenidos con el umbral de 1dl. El porcentaje global se incrementa entre un 19% en los meses fríos y un 32% en los cálidos, mientras que  $\overline{\%Y_t : Y_{t-1}}$  mejora en un 7% en las tres épocas a pesar de que se producen pérdidas en la predicción correcta de los días húmedos.
- Los porcentajes de días bien previstos logrados con HIRLAM son superiores al 50% en todos los casos, salvo en los comienzos de racha seca de los meses templados. El menor porcentaje global es un 77% y el menor valor de  $\overline{\%Y_t : Y_{t-1}}$  un 72% para los meses templados.
- Los porcentajes de días bien predichos con la previsión basada en HIRLAM son superiores ahora a los de los modelos estadísticos, con la excepción de los días húmedos precedidos de uno húmedo, mayor para los modelos estadísticos en las tres épocas, y el de inicio de racha húmeda en los meses fríos y cálidos.

#### 4.4.4 Conclusiones

En el breve periodo que ha sido posible estudiar, HIRLAM pronostica para Zaragoza unas condiciones de humedad que están muy alejadas de las que se observan; las previsiones son, en general, mayores que las registradas y no reproducen el ciclo estacional observado, por lo que se han descartado como predicciones de la cantidad diaria. Debido a ese desajuste, la predicción de ocurrencia basada en el umbral de 1dl da lugar a porcentajes de éxito peores que los obtenidos por los modelos estadísticos.

En nuestra opinión, el modelo de convección no está bien ajustado y la predicción LSP presenta problemas en la época final de Verano e inicial de Otoño. No obstante, un pequeño ajuste de la previsión HIRLAM nos ha permitido mejorar los porcentajes de éxito en la predicción de ocurrencia de lluvia apreciable.

## 4.5 Conclusiones y líneas futuras de trabajo

Los modelos ajustados en este capítulo usando las covariables disponibles hasta las 18 horas del día anterior han resultado útiles para la predicción de la ocurrencia de lluvia pero no alcanzan a establecer una previsión aceptable de la cantidad registrada.

Se concluye que es mejor establecer la previsión de ocurrencia a partir del umbral de la frecuencia relativa que con el umbral 0.5. Aquél permite obtener predicciones correctas en la mayoría de los días húmedos, más raros en Zaragoza: con el modelo anual, en un 86.4% de los días lluviosos precedidos de uno húmedo y en un 61% de los días iniciales de racha húmeda, ver tabla B.2.

El inconveniente es que existen días secos, sobre todo en los inicios de racha, mal predichos. Cada umbral favorece la predicción de un tipo de día, húmedo con la frecuencia relativa y seco con el valor 0.5, por lo que se hace necesario investigar una definición que recupere las buenas propiedades de ambos y evite, en lo posible, sus problemas.

En relación con los modelos estacionales ajustados cabe concluir que su interpretación es más simple pero que, salvo en los meses templados, no tienen más capacidad predictiva que el modelo anual, que contiene la mayor parte de los efectos que aparecen en los modelos específicos de cada época.

Las predicciones para la ocurrencia de precipitación hechas con los modelos estadísticos se han mostrado más acertadas que las generadas directamente a partir de la cantidad prevista por HIRLAM. Esto representa un acicate para el desarrollo posterior de modelos que ayuden en la previsión local.

Como se ha comentado en el inicio de este capítulo, los meteorólogos del INM utilizan mapas sinópticos con los que valoran, en primer lugar, la previsión para la situación a gran escala para, a continuación, traducir el efecto que producirá esa situación, atendiendo a las características locales. Siguiendo este esquema de trabajo, una mejora del modelo estadístico se obtendría incorporando la información climática referente a una zona suficientemente amplia para poder caracterizar la situación atmosférica en el punto de interés, en el horizonte de previsión. Una alternativa consistiría en definir modelos basados en las medidas existentes en observatorios en los que el INM dispone de radiosondeo: Santander, La Coruña, Madrid y Palma de Mallorca, junto con alguno del sur de Francia, Burdeos por ejemplo. Como se señaló en el

capítulo 3, otra alternativa puede basarse en utilizar la información de algún reanálisis para ajustar modelos estadísticos con mayor periodo de estimación y usando las covariables correspondientes a la malla que se considere; en este caso, el uso operativo del modelo sería factible imputando en el predictor los valores de las covariables utilizadas previstos por HIRLAM.

En este sentido, el desarrollo de modelos específicos para cada época del año parece necesario por dos motivos. Por una parte, la introducción de información de una red espacial implica el uso de un número sensiblemente mayor de covariables, por lo que puede ser necesario construir modelos específicos más simples. Por otra parte, las covariables climáticas relevantes para cada época pueden ser distintas: la definición de éstas ha estado ligada a la frecuencia de las situaciones sinópticas que afectan a amplias zonas peninsulares.

Por último, la escasa utilidad del modelo Gamma para obtener una previsión de la cantidad diaria, cuando ésta es positiva, no nos parece resoluble pese a la inclusión de más información. Como alternativa nos planteamos adoptar el esquema de previsión que sigue el INM, que establece la probabilidad de que la lluvia diaria supere determinados umbrales. Esta aproximación a la predicción de la cantidad supone un tratamiento paralelo al de la previsión de ocurrencia.

## Capítulo 5

# Downscaling estadístico de la precipitación diaria. Proyecciones del cambio climático en el área de Zaragoza

### 5.1 Introducción

Existen numerosas publicaciones y congresos en los que se presentan análisis científicos relativos a la variabilidad climática a escala regional de la precipitación, su cambio en el tiempo y su posible evolución futura. En España se han financiado, por parte de CICYT y otros organismos, proyectos de investigación dedicados al análisis retrospectivo de esa evolución, López y Brunet (2001) [85], Rodríguez-Puebla y otros (2001) [100], González y otros (2002) [48], Abaurrea y otros (2002) [10].

Para establecer escenarios sobre su comportamiento futuro es necesario construir modelos que la simulen adecuadamente en la situación actual; sólo de ese modo las proyecciones futuras pueden ser creíbles. El objetivo de este capítulo es proponer y analizar un procedimiento estadístico, basado en la modelización presentada en los capítulos anteriores, que permita obtener proyecciones sobre la precipitación diaria en un observatorio, en un escenario de cambio climático.

En la sección 5.2 se describe el marco en el que se realiza la investigación sobre el cambio climático, las herramientas utilizadas y los organismos que participan y la promueven, entre los que destaca el IPCC (Intergovernmental Panel on Climate Change). En la sección 5.3 se revisan las referencias

metodológicas sobre el downscaling estadístico y se describen las hipótesis requeridas para que ese procedimiento sea útil. La sección 5.4 describe algunas características de los modelos de circulación general (GCM) que el IPCC considera de referencia; en particular se comenta el modelo CGCM1, desarrollado por el Canadian Center for Climate Modelling and Analysis, cuyos datos se van a utilizar.

La sección 5.5 presenta el método de downscaling propuesto con sus distintos pasos. En la 5.6 se comparan los resultados de un experimento del GCM canadiense, correspondientes a la situación actual, y los datos observados en Zaragoza.

El resto del capítulo se dedica al ajuste de los modelos estadísticos necesarios y a su aplicación al downscaling de la precipitación en el área elegida. El modelo que explica mayor variabilidad de la respuesta se estudia en la sección 5.7 y se usa para el downscaling de la lluvia diaria en el periodo 1990-2000, en la 5.8. La mala reproducción del régimen de lluvia observado cuando se usa el modelo con los valores simulados por CGCM1, nos lleva a ensayar, en la sección 5.9, distintos modelos estadísticos con el fin de obtener un segundo modelo que presente menor sesgo. El downscaling de la precipitación para el intervalo 2090-2100 se lleva a cabo en la sección 5.10.

Finalmente la sección 5.11 resume las principales conclusiones obtenidas, señalando los problemas abiertos y las futuras líneas de investigación.

## 5.2 El estudio del cambio climático

El interés de la comunidad internacional por este tema llevó a la Organización Meteorológica Mundial (WMO) y al Programa Medioambiental de Naciones Unidas (UNEP) a establecer un organismo, denominado IPCC, que centralizara y difundiera los avances científicos en este campo. Una de las tareas del IPCC es la preparación de documentos y la gestión de bases de datos que faciliten el trabajo de los investigadores del cambio climático. Periódicamente se publican informes de carácter global que recogen el estado de la investigación en sus diversos aspectos, científico, socio-económico y técnico, Houghton y otros (1990) [59], (1996) [63] y (2001) [64]. Entre los informes de carácter más específico resulta de especial interés el desarrollado para servir de guía en los estudios sobre cambio climático, IPCC-TGCIA (1999) [68].

El IPCC ha contribuido a establecer un marco para el desarrollo de los estudios climáticos, la obtención de proyecciones en escenarios futuros y a

facilitar que los estudios sean comparables. Un escenario es "una descripción plausible de cómo puede evolucionar el futuro, sobre la base de una serie coherente e intrínsecamente homogénea de hipótesis sobre relaciones y fuerzas motrices esenciales"<sup>1</sup>. En el informe de Houghton y otros (1992) [60] se establecieron los escenarios denominados IS92, utilizados desde entonces en los estudios de cambio climático. Corresponden a propuestas sobre las futuras emisiones de gases de efecto invernadero y gases precursores de aerosoles, basadas en hipótesis relacionadas con el crecimiento económico y de la población, el uso de la tierra, los cambios tecnológicos, la disponibilidad de energía y la utilización de combustible en el periodo 1990-2100. En el escenario IS92a, uno de los más usados entre los 6 propuestos, las emisiones de CO<sub>2</sub> acumuladas de 1991 a 2100 son de 1400 GtC, lo que supone un valor medio dentro del conjunto de los escenarios IS92. Señalemos como referencia que las emisiones durante el periodo 1860-1994 ascendieron a unas 360 GtC, de las que 240 se debieron al uso de combustibles fósiles y 120 a la deforestación y cambios en el uso de la tierra.

Más recientemente, el IPCC ha desarrollado los escenarios SRES, denominados así porque fueron presentados en el informe *Special Report on Emissions Scenarios*, Nakicenovic y Swart (2000) [93]. Son un conjunto de 40 escenarios, agrupados en cuatro familias, que se corresponden con distintas hipótesis de desarrollo económico y demográfico y que, a priori, cubren el rango de la posible evolución de las emisiones a la atmósfera de los gases de efecto invernadero y aerosoles.

Para obtener proyecciones del posible cambio climático es necesario utilizar modelos que simulen todos los procesos importantes que gobiernan la evolución del clima. Estos modelos de circulación general son las herramientas más sofisticadas para representar el complejo comportamiento de la atmósfera. En los informes del IPCC pueden encontrarse descripciones de estos modelos que, actualmente, se consideran capaces de reproducir adecuadamente la circulación de las variables atmosféricas más estables. Los modelos se basan en las leyes físicas que rigen el desplazamiento de los flujos a gran escala, modelizadas mediante ecuaciones matemáticas que se resuelven usando una red tridimensional sobre el globo terrestre; su desarrollo ha sido paralelo al incremento de la potencia de los computadores. Los principales componentes del sistema climático (atmósfera, océano, superficie terrestre, criosfera y biosfera) se representan por submodelos; se denominan modelos acoplados atmósfera-océano a los que consideran estos componentes de

---

<sup>1</sup>Definición extraída del glosario de términos del IPCC

manera conjunta.

Otra tarea del IPCC es hacer accesibles los datos que producen los experimentos realizados con los GCM en los diversos centros de investigación. El centro de distribución de datos se encuentra en la página <http://ipcc-ddc.cru.uea.ac.uk>.

En el tercer informe del IPCC, Houghton y otros (2001) [64], se concluye que los modelos numéricos han mejorado desde el segundo informe y que los modelos acoplados siguen siendo las herramientas adecuadas para producir las proyecciones del clima futuro. En particular se señala que los modelos acoplados producen simulaciones creíbles del clima presente en los valores medios anuales y en el ciclo estacional, a escala subcontinental, para la mayoría de variables de interés. No existe un modelo que se pueda considerar óptimo, por lo que el IPCC recomienda utilizar varios e interpretar el conjunto de proyecciones.

Un GCM debe representar adecuadamente el clima en las condiciones actuales, para poder considerar verosímiles los resultados que propone en condiciones futuras. Aunque la capacidad de los ordenadores se ha incrementado en los últimos años, la resolución horizontal de los modelos acoplados (del orden de 50000 Km<sup>2</sup>) no permite captar las características de variables con un comportamiento más local, en particular de la precipitación, Wilby y Wigley (2000) [119]. Según estos autores, muchos de los procesos físicos influyentes, como los hidrológicos, los de evolución de las nubes o las convecciones oceánicas, se producen en una escala espacial menor que la del modelo, por lo que no pueden ser resueltos explícitamente. Sus efectos medios son incluidos, de forma aproximada, mediante algún procedimiento de parametrización basado en las relaciones con las variables de gran escala.

En el capítulo 10 del último informe del IPCC, Houghton y otros (2001) [64], se revisan los cambios proyectados por los GCM en distintas variables, entre ellas la precipitación, para una situación correspondiente a finales del s. XXI. El cambio previsto para la lluvia en los diferentes modelos es muy discrepante, como puede verse en el gráfico de la página 597 del volumen I de dicho informe, donde se representa la magnitud de los cambios previstos. La lluvia sigue siendo una de las variables con mayor incertidumbre en cuanto a su comportamiento futuro.

Teniendo en cuenta las diferencias en las proyecciones de lluvia se hace necesario el uso del ‘downscaling’, es decir, de herramientas que relacionen las variables bien representadas con las que tienen un comportamiento más

local. Esta relación será empleada posteriormente en el establecimiento del escenario de cambio climático para estas variables locales más difíciles. En el capítulo 10 del informe de 2001 del IPCC, dedicado al procedimiento de downscaling, se reflejan los esfuerzos realizados por la comunidad científica para estudiar más variables y desarrollar métodos que refinen los resultados tanto en la escala temporal como espacial.

Existen dos enfoques básicos para realizar el downscaling. Uno consiste en desarrollar modelos numéricos de escala espacial más reducida y resolución más fina. Estos modelos climáticos regionales (RCM) realizan el downscaling anidados en un GCM y suelen ser desarrollados por los propios centros responsables de éstos, por ejemplo el Canadian RCM o el HadRCM inglés. El segundo enfoque consiste en los métodos estadísticos de downscaling, como el que se propone en este capítulo, que se basan en la estimación de relaciones entre la variable de comportamiento local y las variables de gran escala, bien representadas por los GCM; son procedimientos menos costosos computacionalmente y fácilmente aplicables. Esta finalidad explica, en parte, el interés creciente por los modelos estadísticos de precipitación a escala local o regional, a lo largo de la última década del siglo XX.

## 5.3 Modelos estadísticos de downscaling

Un procedimiento de downscaling estadístico se desarrolla en dos pasos: el primero corresponde al ‘aprendizaje’ de las relaciones estadísticas entre las variables climáticas de influencia local y los predictores de gran escala y, el segundo, a la aplicación de esas relaciones a la salida de un experimento de un GCM para simular las características climáticas de esas variables locales.

En la siguiente subsección se revisan los métodos estadísticos de downscaling de la precipitación diaria encontrados en la literatura. Las hipótesis inherentes al método se describen en la subsección 5.3.2.

### 5.3.1 Revisión de métodos de downscaling de la precipitación diaria

Los modelos para el downscaling estadístico de la precipitación pueden clasificarse de acuerdo con la metodología que utilizan para representar la relación entre ésta y las demás variables climáticas. En un primer grupo se encuentran los modelos basados en regresión y en un segundo los basados en la definición, a partir de las covariables climáticas, de situaciones tipo en cuyo

contexto se modela la lluvia observada. En el capítulo 1 se comentaron algunas referencias en las que se lleva a cabo una revisión de las metodologías de downscaling estadístico.

### Métodos de regresión

El método propuesto en este capítulo se sitúa en la línea de trabajo emprendida por Buishand y colaboradores. Éstos desarrollan métodos de downscaling basados en la modelización de la lluvia diaria utilizando covariables proporcionadas por el reanálisis NCEP/NCAR. En sus trabajos iniciales, Klein Tank y Buishand (1995) [77], Brandsma y Buishand (1997) [22], las proyecciones para la precipitación futura se obtenían mediante la generación de una serie diaria de lluvia en un escenario  $2\times\text{CO}_2$ , a partir de la transformación de la serie observada. La falta de disponibilidad de datos diarios relativos a las proyecciones del GCM, la resolvieron ajustando las probabilidades de ocurrencia de lluvia usando los datos diarios observados, modificados de acuerdo con los cambios medios estacionales proyectados. Una vez calculada la frecuencia esperada de días de lluvia en cada estación, ajustaban adecuadamente la serie observada de lluvia, bien transformando en húmedos los días secos con mayor probabilidad ajustada de lluvia, bien transformando en secos los días húmedos con menor probabilidad. El valor medio de la cantidad diaria lo ajustaban usando las covariables modificadas y el cambio en la cantidad recogida en un día húmedo se obtenía aplicando un factor calculado como el cociente entre el nuevo valor medio ajustado y el valor medio original.

Más recientemente, Beckmann y Buishand (2001) [20] han desarrollado el downscaling basándose en modelos del mismo tipo pero utilizando como predictores los datos diarios de las covariables generados por un GCM en la situación de cambio climático, lo que les permite simular series de precipitación.

En cuanto a las covariables utilizadas, Klein Tank y Buishand (1995) [77], tras comparar los datos del reanálisis con los generados por el GCM canadiense en una situación de control, para la región que rodea al observatorio de De Bilt, concluyeron que la temperatura y la presión en superficie estaban bien representadas por el GCM. Beckmann y Buishand (2001) [20] realizan el downscaling de la precipitación diaria en 12 observatorios europeos utilizando como covariables: la temperatura y humedad relativa a 700hPa, la presión a nivel del mar, las alturas geopotenciales de 500hPa, 850hPa y 1000hPa, el espesor de la capa 1000-500hPa, la baroclinicidad en 700hPa, la

vorticidad y las componentes de viento en 850hPa y 100hPa. Al comparar los valores medios estacionales de estas variables, procedentes del reanálisis NCEP/NCAR, y los de las generadas por el modelo numérico ECHAM4 en la situación actual, identificaron sesgos en los cinco puntos analizados de la red del modelo para las variables humedad, espesor, baroclinicidad, componentes del viento y la vorticidad.

Abaurrea y Asín (1997) [4] realizaron el downscaling de la precipitación diaria en Reinosa y Tortosa usando modelos basados en las temperaturas máxima y mínima en superficie. El cambio proyectado en la precipitación se obtenía comparando los valores ajustados, usando las covariables observadas y las modificadas. En un horizonte a 15 años, los valores diarios de temperatura se modificaron de acuerdo con la tendencia observada en la media mensual; en otro horizonte más alejado, correspondiente a una situación  $2\times\text{CO}_2$ , las temperaturas diarias se modificaron según el cambio proyectado por el GCM canadiense para los valores medios estacionales.

Wilby y otros (1999) [118] realizaron el downscaling de la precipitación en la cuenca del río Animas, Nuevo México, mediante un modelo estadístico que utilizaba la presión media a nivel del mar, la altura del geopotencial 500hPa y la humedad específica media en superficie, todas ellas extraídas del reanálisis NCEP/NCAR. Llevaron a cabo una proyección para el periodo 2081-2095 a partir de los datos de un experimento de HadCM2. En un trabajo posterior, Wilby y Wigley (2000) [119], evaluaron si los datos generados por ese GCM para el clima actual reproducían la relación entre las variables analizadas en seis zonas de Estados Unidos, de características climáticas distintas, entre ellas la cuenca del río Animas. El análisis de las correlaciones entre las variables de temperatura, humedad, componentes del viento en superficie y en el geopotencial 500hPa, simuladas en el periodo 1980-1999, estableció que se reproducía la dependencia observada en Invierno y Verano.

El trabajo de Murphy (2000) [92], que realiza un downscaling de la lluvia mensual en los meses de Enero y Julio usando los datos generados por el modelo HadCM2, es una referencia interesante porque lo aplica en 976 observatorios europeos. El autor valora el interés de utilizar un elevado número de covariables climáticas, que selecciona con el criterio de maximizar la variabilidad explicada. Los predictores seleccionados con mayor frecuencia son: la vorticidad, la humedad relativa en el nivel 850hPa, la presión a nivel del mar y las temperaturas en los geopotenciales 850hPa, 700hPa y 500hPa.

En una línea diferente, Semenov y Barrow (1997) [103] construyen un

modelo para generar rachas de días secos y húmedos, cuya longitud modelizan con una mezcla de Exponenciales, y para la cantidad de lluvia medida en los días húmedos, que modelan también como una mezcla de Exponenciales. Utilizan la información generada por el GCM de la UK Meteorological Office para perturbar sus parámetros y lo aplican a datos de Sevilla y Rothamsted. Para cada mes, realizan la regresión de la precipitación acumulada frente a las anomalías de la presión a nivel del mar y sus gradientes; calculan los valores esperados usando las anomalías de las covariables en la situación de cambio climático y modifican los parámetros del modelo diario de acuerdo con esos valores medios de precipitación. Este trabajo ejemplifica la desventaja, comentada en la sección 3.3, que presenta el uso de modelos de rachas, frente a las modelizaciones de la lluvia que permiten imputar directamente los datos de las salidas de los GCM.

### **Métodos basados en el estado climático**

Estos modelos se han aplicado utilizando tanto series observadas de situaciones climáticas tipo, como series generadas mediante procesos estocásticos, modelos semimarkovianos por ejemplo, y, en ocasiones, evitando su definición explícita mediante el uso de cadenas de Markov ocultas o identificando los patrones usando un método de análogos.

El trabajo pionero de Bardossy y Plate (1992) [19] es del primer tipo. A partir de la serie temporal de estados climáticos obtienen simulaciones del proceso de lluvia en los observatorios de una región usando una variable normal multidimensional, cuyos parámetros dependen del estado reinante, en la que cada distribución marginal define la lluvia en un observatorio. Los autores señalan que este modelo podría ser utilizado con la secuencia de situaciones definidas a partir de los datos de presión generados por un GCM, en aquel momento no disponibles en escala diaria.

Goodess y Palutikof (1998) [49] y Goodess (2000) [50], tras comprobar que la clasificación de situaciones de Lamb para Inglaterra es válida también en España, país donde aplican sus modelos, representan la evolución de los tipos de clima mediante una cadena de Markov. Cada situación tipo tiene asociada una distribución condicional de lluvia dada por una probabilidad de ocurrencia y una distribución de cantidad. Para realizar el downscaling estiman la matriz de probabilidades de transición entre los tipos de clima a partir de las trayectorias simuladas por HadCM; los parámetros de lluvia condicionada al estado se estiman a partir de las observaciones y no se modifican en el escenario futuro. Las autoras comparan los campos de presión

medios estacionales en la simulación de control de HadCM con los observados sobre el Atlántico Norte y concluyen que las medias estacionales son reproducidas aceptablemente pero que las frecuencias mensuales de los distintos tipos de circulación son significativamente distintas de las observadas. Por este motivo, Goodess utiliza en el segundo trabajo los datos de HadCM2, que tiene mejor comportamiento, y basa sus proyecciones en la secuencia de tipos que obtiene de los campos de presión simulados.

Hughes y Guttorp (1994) [66] proponen un modelo de cadena de Markov oculta, no homogénea, para representar la evolución de la situación atmosférica y, a partir de ella, modelan la precipitación diaria en cuatro observatorios del estado de Washington. Las probabilidades de transición de la cadena dependen de las componentes principales extraídas del campo de presión. El modelo se puede utilizar para el downscaling usando los datos de presión generados por un GCM.

Zorita y von Storch (1999) [125] identifican el modo de circulación mediante un método de análogos y realizan el downscaling de la lluvia diaria de Invierno en la Península Ibérica. Como variable caracterizadora del estado atmosférico emplean la presión a nivel del mar, obtenida del reanálisis NCEP/NCAR, por considerar que las alturas geopotenciales están más afectadas por el calentamiento global y que sus cambios están menos relacionados con las variaciones en la circulación atmosférica. El procedimiento identifica la situación observada del campo de presión más similar a la propuesta por el GCM y asocia la precipitación observada en el día seleccionado.

El principal problema de estas metodologías, en nuestra opinión, es que la definición del estado climático depende exclusivamente del campo de presión que, como señala Goodess, es poco sensible al cambio climático, por lo que las simulaciones del GCM en el clima perturbado producen cambios pequeños en la frecuencia de los tipos de circulación. Pensamos que interesa trabajar con modelos que incorporen variables atmosféricas diversas, que caractericen mejor la precipitación y que, además, reflejen los distintos aspectos del cambio climático: incrementos en temperatura, humedad, etc.

### 5.3.2 Hipótesis y crítica de los modelos estadísticos de downscaling

El uso de modelos estadísticos para la realización del downscaling supone que se verifican dos hipótesis de difícil comprobación:

1. Las relaciones establecidas con los datos observados deben permanecer

invariantes, aunque las condiciones climáticas generales hayan cambiado.

2. El modelo estadístico, estimado a partir de los datos de un número limitado de años, debe ser capaz de reproducir los ciclos de longitud decadal o superior que presenta la precipitación.

Si se dan esas condiciones y si la salida del GCM caracteriza bien la situación climática en el área de interés, es posible producir escenarios que trasladen a las variables locales los cambios en el clima futuro, mejorando las proyecciones proporcionadas por los GCM.

No hay en la literatura estudios que analicen estas hipótesis básicas en el downscaling de la lluvia diaria. Como una aproximación citaremos el trabajo de González-Rouco y otros (2000) [47], en el que estudian si su método para el downscaling de la precipitación acumulada en Invierno verifica esas hipótesis. Realizan un análisis de correlación canónica entre la precipitación en los observatorios de un área que incluye a la Península Ibérica y el campo de presión media a nivel del mar sobre el Atlántico Norte, obtenido de NCAR. Con el fin de estudiar la capacidad del modelo para reproducir la precipitación en distintas situaciones, lo aplican a los periodos 1899-1939 y 1980-1989, de diferente carácter climático, obteniendo resultados de una calidad análoga. Además, encuentran que las tendencias observadas en la precipitación en el periodo 1930-1989 son semejantes a las de los datos simulados, por lo que concluyen que si el método es capaz de reproducir las tendencias observadas, sus proyecciones de la precipitación en el escenario de cambio son verosímiles.

## 5.4 Disponibilidad de datos diarios generados por los modelos de circulación general

Se ha realizado una búsqueda, a través de Internet, de los datos de escala diaria generados en los experimentos con los GCM y se ha consultado con investigadores que están a cargo de las bases de datos en diversos centros de investigación o que trabajan con información diaria. La búsqueda se inició en el centro de distribución de datos (DDC) del IPCC, mantenido por la Climatic Research Unit (CRU) de la Universidad de East Anglia (Reino Unido) y por el organismo alemán de investigación climática, Deutsches Klimarechenzentrum (DKRZ). El DDC proporciona información agregada mensual de distintos experimentos realizados con siete modelos considerados de referencia por el IPCC:

1. Modelo CSIRO-Mk2, desarrollado por la Australia's Commonwealth Scientific and Industrial Research Organisation (CSIRO).
2. Modelos ECHAM4/OPYC3 y ECHAM3/LSG, del DKRZ, Alemania.
3. Modelos HadCM2 y HadCM3, del Hadley Centre for Climate Prediction and Research (HCCPR), Reino Unido.
4. CGCM1, del Canadian Center for Climate Modelling and Analysis.
5. GFDL-R15-a, del Geophysical Fluid Dynamics Laboratory (GFDL), Estados Unidos.
6. Los modelos NCAR1NCAR y NCAR DOE-PCMNCAR3, desarrollados en el NCAR, Estados Unidos.
7. CCSR/NIES, del Center for Climate Research Studies (CCSR) y National Institute for Environmental Studies (NIES), Japón.

El DDC no proporciona datos diarios y dirige para su obtención a los centros de investigación. Por este motivo se buscó información en algunos de los centros citados.

### CSIRO

Ha desarrollado un modelo acoplado (CSIRO9 coupled GCM) que tiene una resolución de 350 Km  $\times$  625 Km. Con él se ha simulado un escenario de incremento del CO<sub>2</sub> que proyecta un calentamiento global de 2.2°C en la situación 2 $\times$ CO<sub>2</sub>, que se alcanza tras 130 años.

El contacto con Roger Jones, responsable de la distribución de datos, dio como resultado el ofrecimiento de los datos diarios de la presión a nivel del mar, la tasa de lluvia, las temperaturas máxima y mínima, la humedad relativa y la velocidad del viento en superficie del modelo.

### **DKRZ**

El modelo ECHAM4 se basa en uno de previsión climática del ECMWF, modificado por el Max Planck Institute for Meteorology y el DKRZ y se encuentra en su cuarta versión. Considera 19 niveles en la atmósfera, hasta un nivel de presión de 10hPa, y tiene una resolución aproximada de  $2.8^\circ \times 2.8^\circ$ .

Los resultados se proporcionan a través de la base de datos CERA (Climate and Environmental Data Retrieval and Archive) pero el acceso directo a los datos diarios no era factible cuando lo intentamos. Eduardo Zorita mostró su disposición para hacer la extracción de los datos de este modelo.

### **Hadley Center**

El Hadley Center ha desarrollado dos modelos acoplados atmósfera-océano, HadCM2 y HadCM3. Este último tiene una resolución horizontal en el modelo de atmósfera de  $2.5^\circ \times 3.75^\circ$  y 19 niveles verticales; el modelo de océano tiene 20 niveles y una resolución espacial de  $1.25^\circ \times 1.25^\circ$ .

El administrador David Viner nos concedió permiso para disponer de los datos diarios vía ftp; el acceso, sin embargo, no era ágil puesto que no existía, a disposición de los usuarios externos, la herramienta informática apropiada para hacer una extracción selectiva del periodo y la región deseada.

### **CCCma**

El modelo CGCM1 se ha desarrollado en el Canadian Centre for Climate Modelling and Analysis (CCCma), situado en la ciudad de Victoria. Una descripción exhaustiva de sus características se puede encontrar en Hengeveld (2000) [57] y en Flato y otros (2000) [41]. Hemos seleccionado CGCM1 por la facilidad para acceder y extraer, a través de Internet, los datos diarios.

El modelo está constituido por cuatro componentes:

1. Un modelo de circulación general de la atmósfera, denominado GCMII, con 10 niveles verticales y una resolución de  $3.7^\circ \times 3.7^\circ$ .

2. Un modelo de circulación general oceánica basado en el modelo MOM, desarrollado en el Geophysical Fluid Dynamics Laboratory de Princeton. Tiene 29 niveles verticales y una resolución horizontal de unos 200 Km.
3. Un modelo termodinámico para el hielo marino.
4. Un modelo de superficie terrestre que calcula la escorrentía y la humedad del suelo como balance de la precipitación, la evaporación y su capacidad de almacenamiento.

La evaluación de este modelo se ha realizado contrastando su capacidad para reproducir las características del clima presente, con resultados satisfactorios para las temperaturas medias globales, los niveles de presión y la circulación atmosférica. Se han realizado también comparaciones entre los valores simulados y observados en épocas con diferente clima de los últimos 150 años.

Con el modelo CGCM1 se habían realizado en Junio de 2001 tres experimentos: (a) una integración de control, con nivel constante de CO<sub>2</sub>, (b) una integración (GHG) que utiliza el incremento histórico de CO<sub>2</sub> entre 1900 y 1989 y un incremento anual del 1% para el periodo 1990-2100 y (c) un conjunto de 3 integraciones<sup>2</sup> (GHG+A) donde se tiene en cuenta, además, el efecto de los aerosoles. Estas últimas consideran un incremento histórico de CO<sub>2</sub> entre 1900 y 1996 y una tasa de crecimiento del 1% anual para el periodo 1996-2100; la concentración de aerosoles es la correspondiente al incremento histórico de SO<sub>4</sub> en el periodo 1900-1989 y a su evolución de acuerdo con el escenario IS92a, en el periodo 1990-2100.

El centro permite un rápido acceso a la información mensual y anual de los tres experimentos pero únicamente proporciona datos diarios del experimento GHG+A. De éste, están disponibles, para una de las simulaciones, los datos de 16 variables de superficie y de 5 en los niveles geopotenciales 850hPa y 500hPa. Cada variable puede obtenerse en las celdas que se especifiquen de la red y para el periodo deseado entre los años 1961 y 2100.

Recientemente el CCCma ha desarrollado una versión mejorada de este modelo, denominada CGCM2, en la que se han modificado algunos elementos del modelo oceánico y de la dinámica del hielo marino. Con esta nueva versión se han realizado experimentos en los mismos escenarios y en algunos de la

---

<sup>2</sup>Un conjunto de integraciones representa varias simulaciones con idéntica situación en el forzamiento y distintas condiciones iniciales.

familia SRES; en Noviembre de 2002 empezaban a estar disponibles datos diarios.

## 5.5 Método de downscaling propuesto

El procedimiento de downscaling se va a basar en una versión del modelo de lluvia desarrollado en el capítulo 3, que se ajustará utilizando las variables o anomalías que CGCM1 represente adecuadamente en Zaragoza.

Este procedimiento se desarrolla en varios pasos:

1. Análisis y selección de las variables bien representadas por el modelo en la celda de su malla que contiene al observatorio:

Estudio de sus características en la situación presente, años 1990-2000, y comparación con el clima observado. Análisis de las medidas de posición y dispersión, de la relación de dependencia entre las observaciones consecutivas así como la de las distintas variables entre sí.

2. Ajuste del modelo de precipitación diaria a partir de los datos observados en el aeropuerto de Zaragoza:

El modelo sólo utilizará las variables climáticas que, de acuerdo con el análisis anterior, estén bien representadas en el GCM; se estimará con los datos del periodo 1990-1997 y se validará con los de 1998-2000.

3. Evaluación del modelo ajustado mediante un downscaling de la precipitación en el periodo 1990-2000:

El objetivo de este paso es asegurar que el modelo ajustado reproduce el régimen observado de lluvia cuando se usan como predictores las covariables simuladas por el GCM en las condiciones actuales e identificar, en otro caso, sus sesgos. Para ello se realiza un estudio comparativo análogo al que desarrollan Goodess (2000) [50], Beckmann y Buishand (2001) [20] o el proyecto europeo POPSICLE (2000) [76]:

- (a) Se comparan la frecuencia de días húmedos y la cantidad total de lluvia recogida anual y estacionalmente. El número esperado de días de precipitación se calcula como la suma de las probabilidades de ocurrencia; la cantidad de lluvia esperada en un periodo se calcula como la suma de las cantidades asociadas a cada día del mismo, que se obtienen como producto de la probabilidad de ocurrencia por el valor ajustado de cantidad.
- (b) Se simula el modelo de lluvia para obtener las características de la distribución de las longitudes de racha, seca y húmeda, y de la cantidad de precipitación diaria, que se comparan con las observadas.

4. Proyección en una situación de cambio climático, representada por los valores de las covariables que produce la integración GHG+A para el periodo 2090-2100:

Se valora el impacto en el régimen de lluvia en ese escenario, aplicando la metodología del apartado anterior.

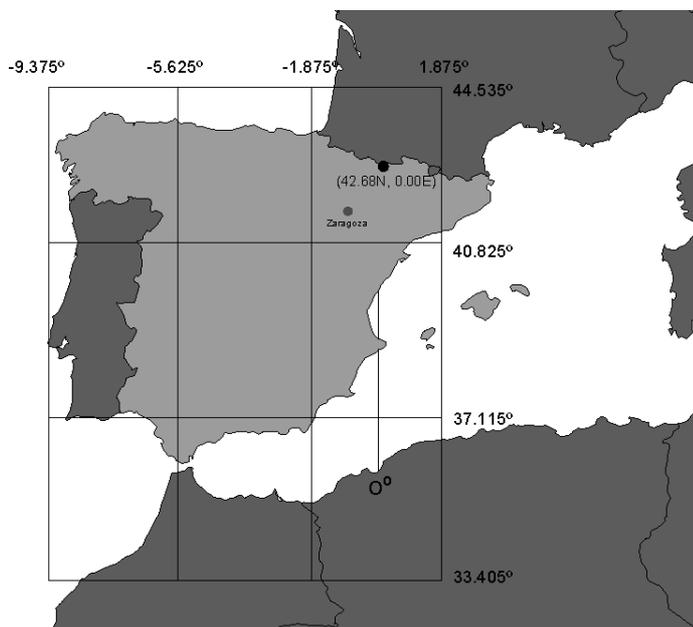


Figura 5.1: Posición de las celdas consideradas del modelo CGCM1.

## 5.6 Datos extraídos de CGCM1 y comparación con el clima observado

El acceso a los datos se obtiene, tras el registro como usuario, en la dirección [http://www.cccma.bc.ec.gc.ca/data/cgcm1/cgcm1\\_ghga.shtml](http://www.cccma.bc.ec.gc.ca/data/cgcm1/cgcm1_ghga.shtml)

Se ha extraído la información de la celda centrada en el punto (42.68N, 0.00E), donde se encuentra el observatorio de Zaragoza-aeropuerto (41.66N, 1.01W). Los años extraídos corresponden al periodo 1990-2000, para el que disponemos de medidas de radiosondeo, y los del intervalo 2090-2100. Para realizar algunas comparaciones adicionales se han obtenido datos de 8 celdas que recubren la Península Ibérica, ver figura 5.1. La tabla 5.1 reproduce la solicitud de datos en Internet para las nueve celdas de interés.

Las variables extraídas han sido las cinco disponibles en los niveles geopotenciales 500 y 850hPa y, de las 16 variables de superficie, las utilizadas en el modelo del capítulo 3; se han extraído también los valores de la precipitación diaria propuestos por el modelo. En la tabla 5.2 se indican las variables seleccionadas y la notación utilizada para expresarlas.

La información relativa a la humedad es proporcionada por el GCM en

Model: CGCM1	Run: GHG+A 1	Grid: Lat/Lon
Variable: 500hPa Temp.	Years: 1990-2000	Months: 1-12
Selected region. User defined		
Lower left corner:	I1=95 J1=34	(7.50W, 35.26N)
Lower right corner:	I2=1 J1=34	(0.00E, 35.26N)
Upper left corner:	I1=95 J2=36	(7.50W, 42.68N)
Upper right corner:	I2=1 J2=36	(0.00E, 42.68N)
Area dimensions: 3 grid cells (lon.) x 3 grid cells (lat.)		

Tabla 5.1: Extracción de información para las 9 celdas seleccionadas.

850 hPa	Altura geopotencial	0h	(metros)	A850.00
	Temperatura	0h	(°C)	T850.00
	Humedad específica	0h	(kg/kg)	Q850.00
	Componente U viento	0h	(m/seg)	U850.00
	Componente V viento	0h	(m/seg)	V850.00
500 hPa	Altura geopotencial	0h	(metros)	A500.00
	Temperatura	0h	(°C)	T500.00
	Humedad Específica	0h	(kg/kg)	Q500.00
	Componente U viento	0h	(m/seg)	U500.00
	Componente V viento	0h	(m/seg)	V500.00
Superficie	Temperatura máxima	diaria	(°C)	TMAX
	Temperatura mínima	diaria	(°C)	TMIN
	Presión atmosférica	media 0, 12h	(hPa)	PSUP
	Humedad Específica	media diaria	(kg/kg)	QSUP
	Componente U viento	media diaria	(m/seg)	USUP
	Componente V viento	media diaria	(m/seg)	VSUP
	Precipitación	diaria	(mm)	Q

Tabla 5.2: Variables extraídas de CGCM1 y notación utilizada.

términos de humedad específica (masa de vapor de agua en 1kg de aire); por ello ha sido necesario transformar a esta escala las distintas medidas de humedad observadas: humedad relativa en superficie y temperatura del punto de rocío en los dos niveles geopotenciales.

### 5.6.1 Análisis comparativo de las variables observadas en Zaragoza y simuladas por el modelo

Vamos a comparar, en tres fases, los datos correspondientes a las 17 variables seleccionadas, observados en Zaragoza y los generados por el modelo para la celda que contiene a ese observatorio. En primer lugar se analiza la similitud de sus distribuciones, posteriormente si las series generadas por CGCM1 reproducen la estructura de autocorrelación que tienen las series observadas y, finalmente, se comparan las matrices de correlación entre las distintas variables.

Se ha realizado en los dos conjuntos de datos un análisis descriptivo numérico y gráfico de las variables, así como de algunas variables derivadas: el rango diario de temperatura (*TDIF*), la diferencia de temperatura entre los geopotenciales 850 y 500hPa (*T85/50.00*) y el espesor de la capa entre ellos (*A85/50.00*).

Los valores simulados por el GCM corresponden al clima medio de un área amplia, en la que se incluye Zaragoza. Por este motivo, las discrepancias que se observan entre las series generada y registrada no se deben interpretar como un mal comportamiento del modelo numérico sino como diferencias asociadas a dos climas distintos.

#### Análisis comparativo de la distribución

Para analizar el grado de semejanza entre las distribuciones observada y simulada se han calculado la media, la desviación típica y los cuartiles primero y tercero, tanto globalmente como en las cuatro estaciones del año, ver tablas C.1, C.2 y C.3. Estas tablas se complementan con algunos gráficos: diagramas de caja por meses, que proporcionan una visión del comportamiento estacional de la mediana y la variabilidad de los datos, y suavizados de los valores diarios. La dirección del viento se describe mediante la frecuencia de cada rumbo expresada en rosas de viento de doce direcciones.

Estos gráficos pueden resultar concluyentes para establecer que una variable no está bien representada en el modelo, como ocurre, por ejemplo, con

la precipitación al comparar sus suavizados, ver figura 5.2. En ocasiones, los diagramas de caja por meses nos señalan el interés de analizar comparativamente las anomalías de las variables, ya que la posición central es distinta pero existe semejanza en la variabilidad, caso de la altura del geopotencial 850hPa. Con posterioridad valoraremos mediante contrastes de hipótesis si las distribuciones de las variables o de sus anomalías son próximas.

A continuación se presentan, por bloques de variables, algunas conclusiones de este análisis. El primer bloque está constituido por la precipitación y la humedad, el segundo por las variables de temperatura, el tercero por la presión y las alturas geopotenciales y, finalmente, el viento. En cada bloque se comparan los tres niveles considerados: superficie, 850hPa y 500hPa.

### Precipitación y humedad

- La precipitación está mal representada por CGCM1, ver figura 5.2. Los datos simulados no tienen el comportamiento estacional de un observatorio de clima mediterráneo, con dos estaciones húmedas (Primavera y Otoño) separadas por dos más secas, y reproducen un régimen de precipitación de tipo atlántico con un máximo anual en Invierno.
- Los suavizados de la humedad específica en superficie se encuentran claramente separados aunque muestran paralelismo, ver figura 5.2 inferior; el valor medio global de los datos simulados es un 35% mayor que el observado pero la variabilidad por meses es semejante.
- Los valores simulados de la humedad específica en 850hPa tienen un suavizado parecido al de los datos observados, su nivel es comparable durante los meses más fríos y el máximo en ambos ocurre en Verano. En esta estación el valor medio simulado es un 30% menor que el observado, una discrepancia del orden del rango intercuartílico, ver figura 5.3. La variabilidad es algo mayor en los datos simulados en los meses fríos y en el comienzo de la Primavera.
- En la humedad en 500hPa no se aprecian discrepancias importantes en el nivel medio ni en la variabilidad; esta variable es la que el modelo reproduce mejor.
- Se descarta el uso directo de la humedad en superficie y en 850hPa pero se analizará el uso de sus anomalías.

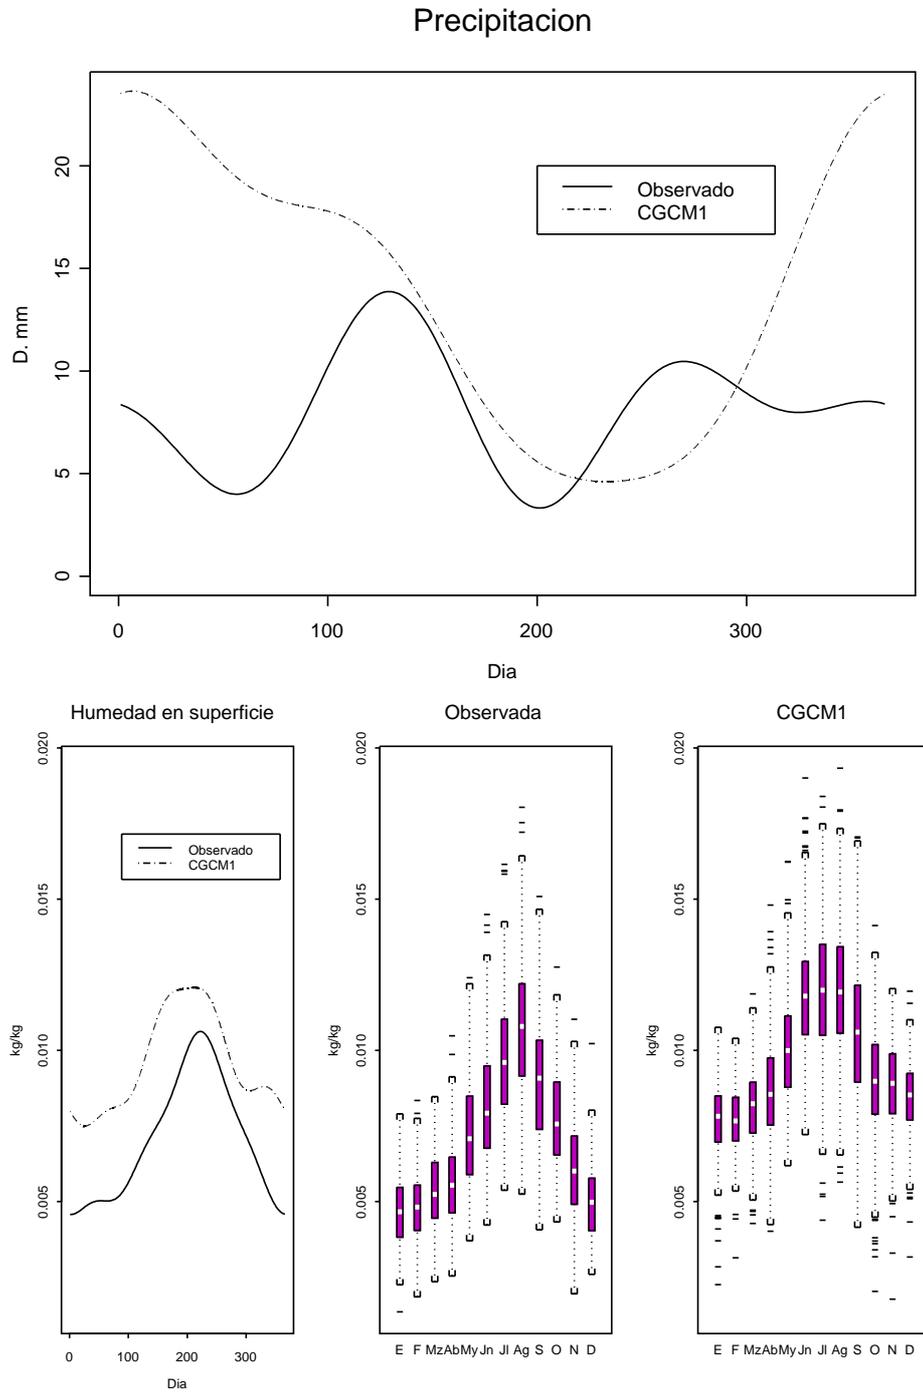


Figura 5.2: Datos diarios de precipitación y humedad en superficie, periodo 1990-2000. Sup.: Valores suavizados de la cantidad diaria de precipitación. Inf.: Suavizados y diagramas de caja por meses de la humedad específica en superficie.

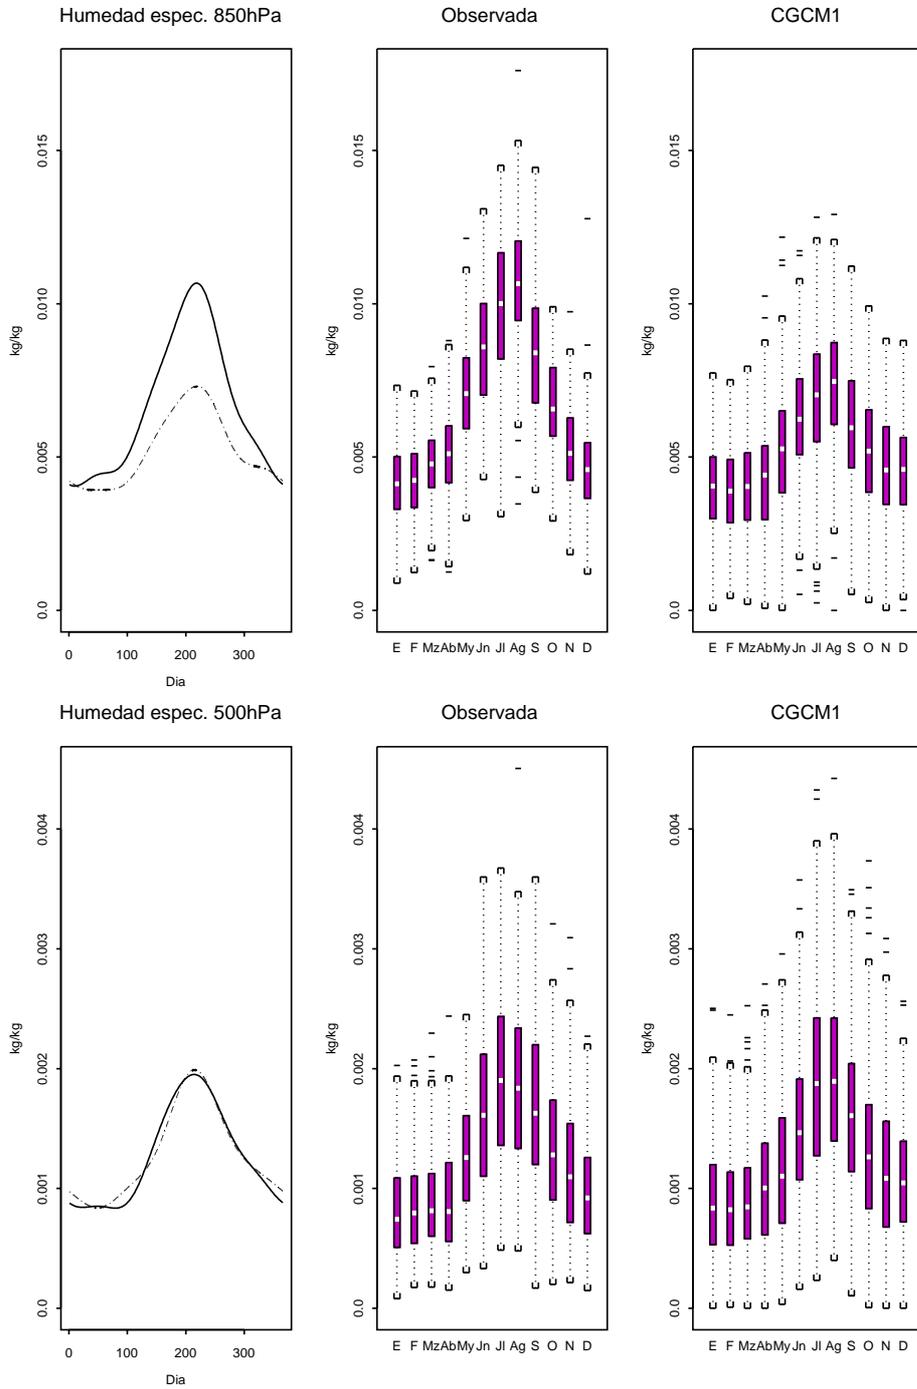


Figura 5.3: Humedad específica en los geopotenciales 850hPa y 500hPa, periodo 1990-2000. Suavizados y diagramas de caja por meses.

### Temperatura

- El ciclo estacional de las temperaturas máxima y mínima diarias en superficie está relativamente bien reproducido, ver figura 5.4, y las medidas globales de posición y dispersión son semejantes. Existen, sin embargo, diferencias destacables en algunas épocas del año.
- La dispersión de los datos simulados de temperatura máxima es menor que la de los observados en Invierno y Primavera y mayor en Verano.
- Las medidas de posición central de las temperaturas mínimas simuladas se sitúan en Invierno  $3^{\circ}\text{C}$  por encima del valor observado, siendo la desviación típica registrada en esa estación  $3.6^{\circ}\text{C}$ . Cabe señalar que el modelo no simula ningún día de helada, cuando ésta ocurre en un 5.7% de los días. La dispersión es semejante en la primera mitad del año pero no en los meses de Otoño y Verano donde los datos simulados tienen una dispersión mayor: en esta última estación la desviación típica es  $4.8^{\circ}\text{C}$  frente a  $2.9^{\circ}\text{C}$  de los datos observados.
- El suavizado del rango diario de temperatura de los datos artificiales se sitúa por debajo del correspondiente a los datos observados en los seis primeros meses del año y por encima en los meses de Otoño, ver figura 5.6. La amplitud de las cajas de los datos simulados es también menor durante la primera mitad del año y mayor en la segunda, en particular en Otoño.
- Las temperaturas simuladas en los geopotenciales 850 y 500hPa muestran un perfil de sus valores medios similar al de los datos observados, ver figura 5.5; los datos simulados de  $T_{500}$  tienen un valor medio  $1^{\circ}\text{C}$  mayor en todas las estaciones, diferencia que cabe considerar leve frente a desviaciones típicas estacionales observadas entre 3 y  $4^{\circ}\text{C}$ .
- La variabilidad de las temperaturas en ambas alturas es diferente en los distintos meses. En el nivel 500hPa los datos observados muestran mayor dispersión, ver figura 5.5, mientras que en  $T_{850}$  los datos simulados presentan dos periodos, uno de mayor dispersión en Verano y otro con menor durante el resto del año, cuando la variabilidad es prácticamente homogénea en los datos observados.
- Las diferencias de temperatura entre los niveles 850 y 500hPa simuladas tienen, también, mayor dispersión en los meses de Julio a Septiembre y menor en Invierno, ver figura 5.6. Las curvas suavizadas se encuentran próximas en Invierno y Otoño, mientras en Primavera los valores

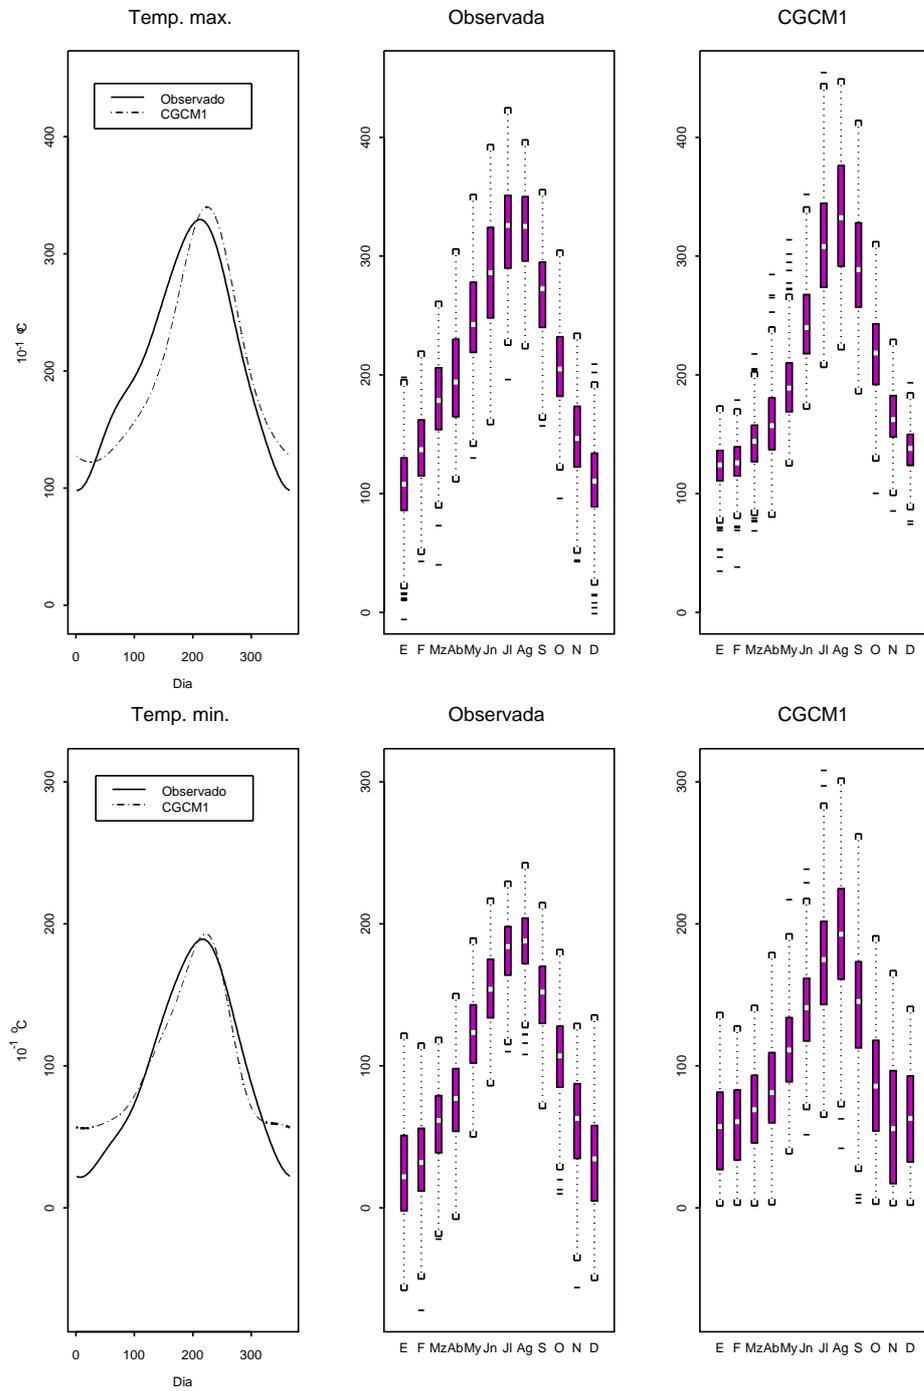


Figura 5.4: Temperatura máxima y mínima, periodo 1990-2000. Suavizados y diagramas de caja por meses.

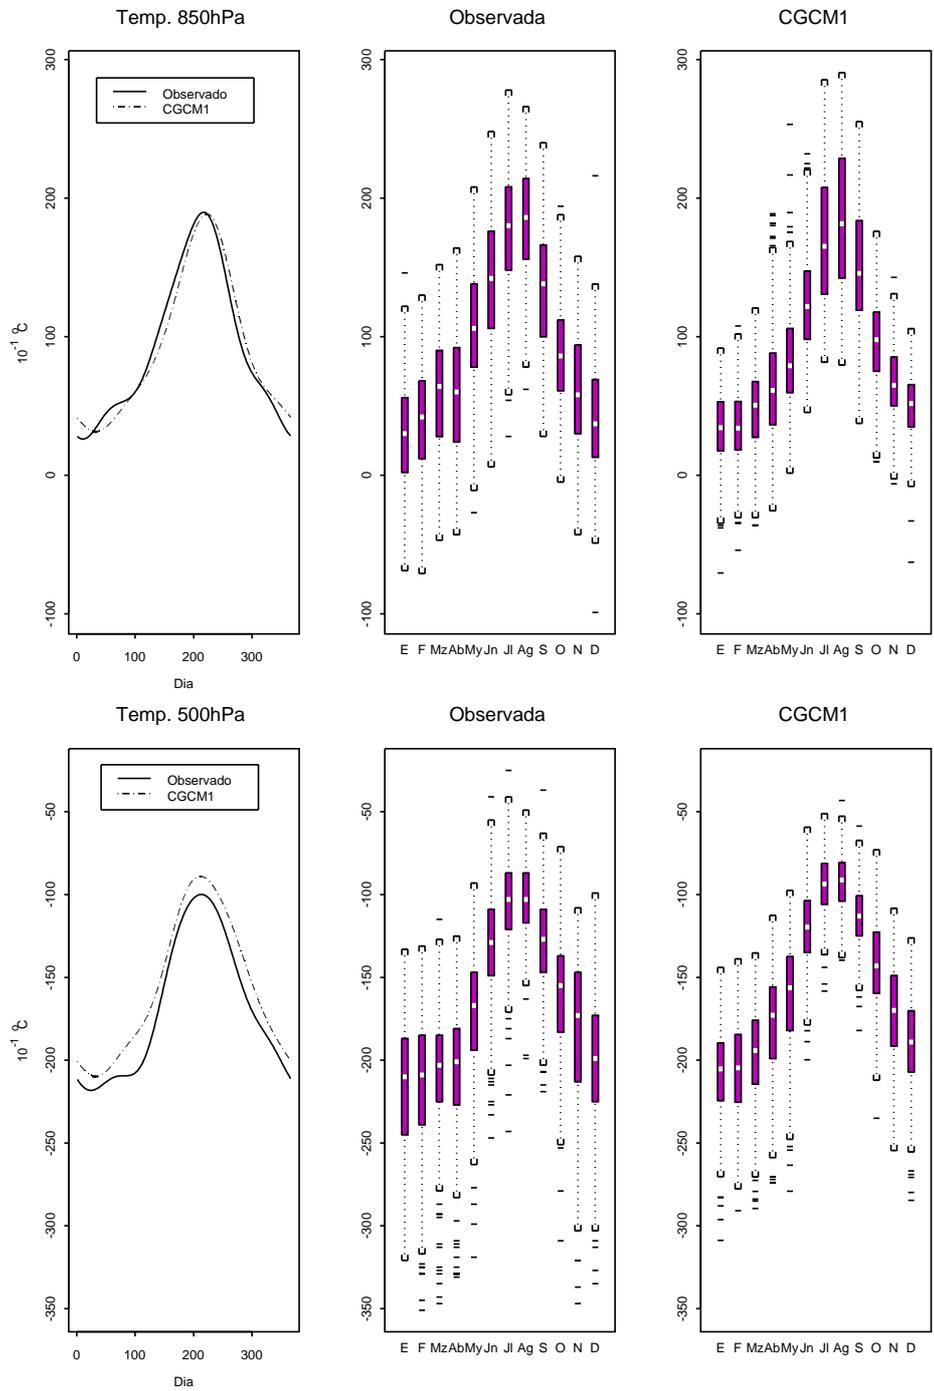


Figura 5.5: Temperatura en los niveles geopotenciales 850 y 500hPa, periodo 1990-2000. Suavizados y diagramas de caja por meses.

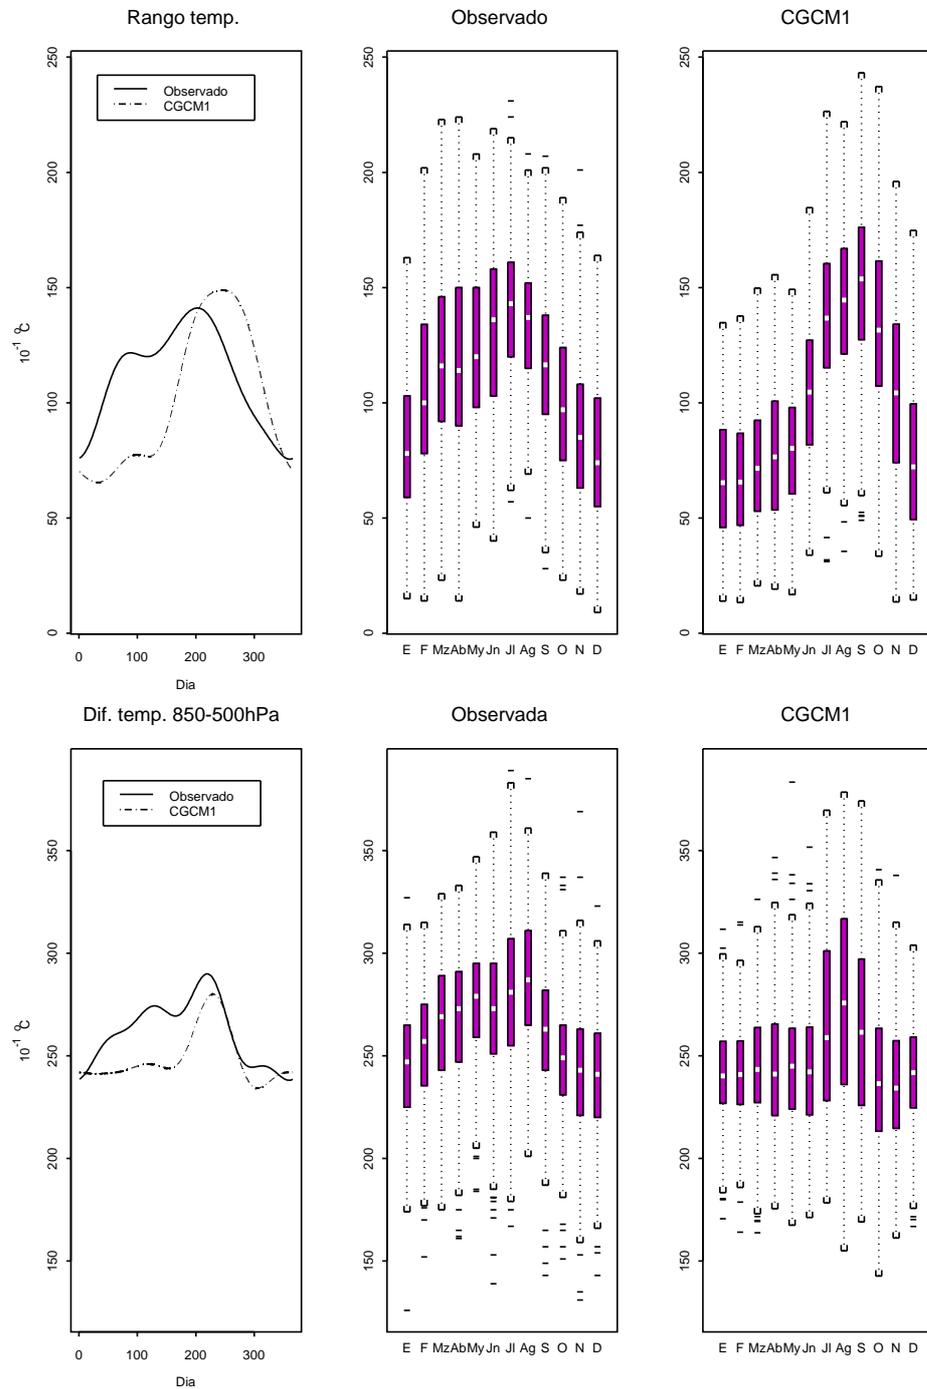


Figura 5.6: Rango de temperatura en superficie y diferencia de temperatura entre los niveles geopotenciales 850 y 500hPa, periodo 1990-2000. Suavizados y diagramas de caja por meses.

medios se diferencian en  $2.4^{\circ}\text{C}$ , cuando la desviación típica observada es  $3.1^{\circ}\text{C}$ .

- Las diferencias observadas en  $TMIN$ ,  $TDIF$  y  $T85/50.00$  hacen que se rechace el uso directo de estas variables y que debamos analizar sus anomalías. Las discrepancias en variabilidad de la temperatura máxima en todos los meses llevan a rechazar su uso y el de sus anomalías. Las discrepancias señaladas en la variabilidad de la temperatura en los dos niveles geopotenciales no nos permite ser concluyentes, deberá analizarse el uso tanto de las variables en altura, ya que los suavizados son similares, como el de sus anomalías.

Presión en superficie y altura geopotencial

- Los suavizados de los datos de presión en superficie son distintos, ver figura 5.7 superior, situándose las discrepancias más importantes alrededor de Abril y Octubre. Entre los meses de Mayo y Agosto hay también diferencia en la dispersión, siendo ésta menor en los datos observados.
- Los valores simulados de la altura geopotencial 850hPa tienen un suavizado distinto al de los observados, ver figura 5.7, siendo esta diferencia en los meses de Verano del orden de su rango intercuartílico mensual. En ambos suavizados existen dos máximos relativos que no se sitúan en la misma época ni son de la misma magnitud: la diferencia en Invierno es de 40 metros a favor de los datos observados, mientras en Verano es superior en 20 metros y se hallan desplazados más de un mes. La amplitud de las cajas es similar en ambos conjuntos de datos.
- Los suavizados de la altura del nivel 500hPa son más semejantes, ver figura 5.8. Los datos simulados producen un valor medio que está 50 metros por debajo del observado en Invierno, donde  $\hat{s} = 114\text{m}$ , y 60 metros en Verano ( $\hat{s} = 75\text{m}$ ). Las alturas simuladas en 500hPa muestran menor dispersión en los meses de Septiembre a Marzo.
- Las dos curvas suavizadas del espesor de la capa 850-500hPa son similares; los datos simulados tienen menor dispersión, siendo las diferencias más acusadas en Otoño e Invierno, ver figura 5.8.
- En estas condiciones no se utilizarán las alturas geopotenciales ni la presión atmosférica, aunque deberá estudiarse la utilización de sus anomalías. Deberá valorarse tanto el uso del espesor de la capa 850-500hPa como de sus anomalías.

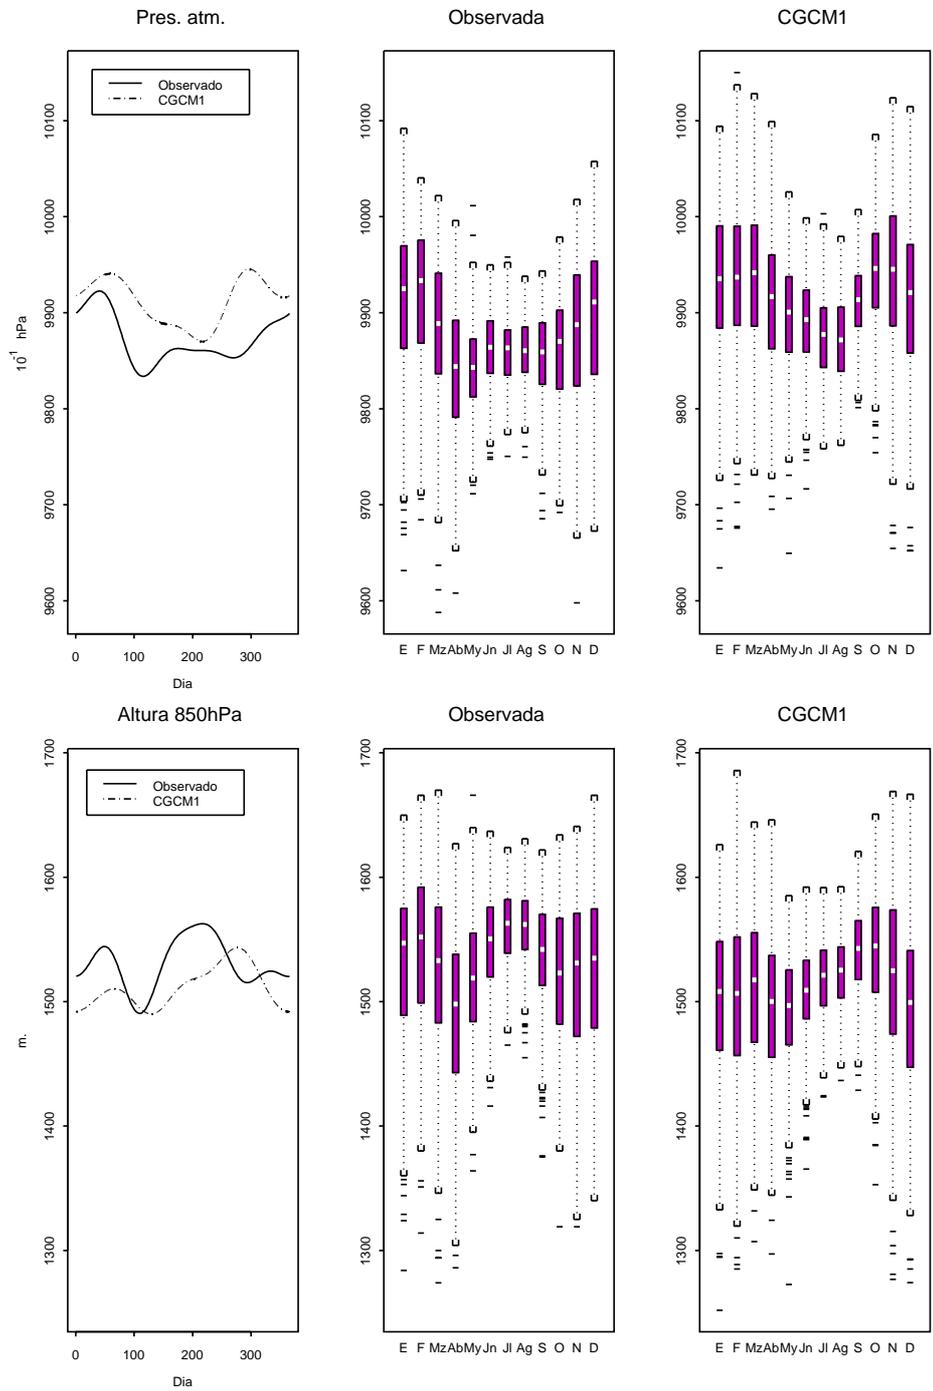


Figura 5.7: Presión en superficie y altura del geopotencial 850hPa, periodo 1990-2000. Suavizados y diagramas de caja por meses.

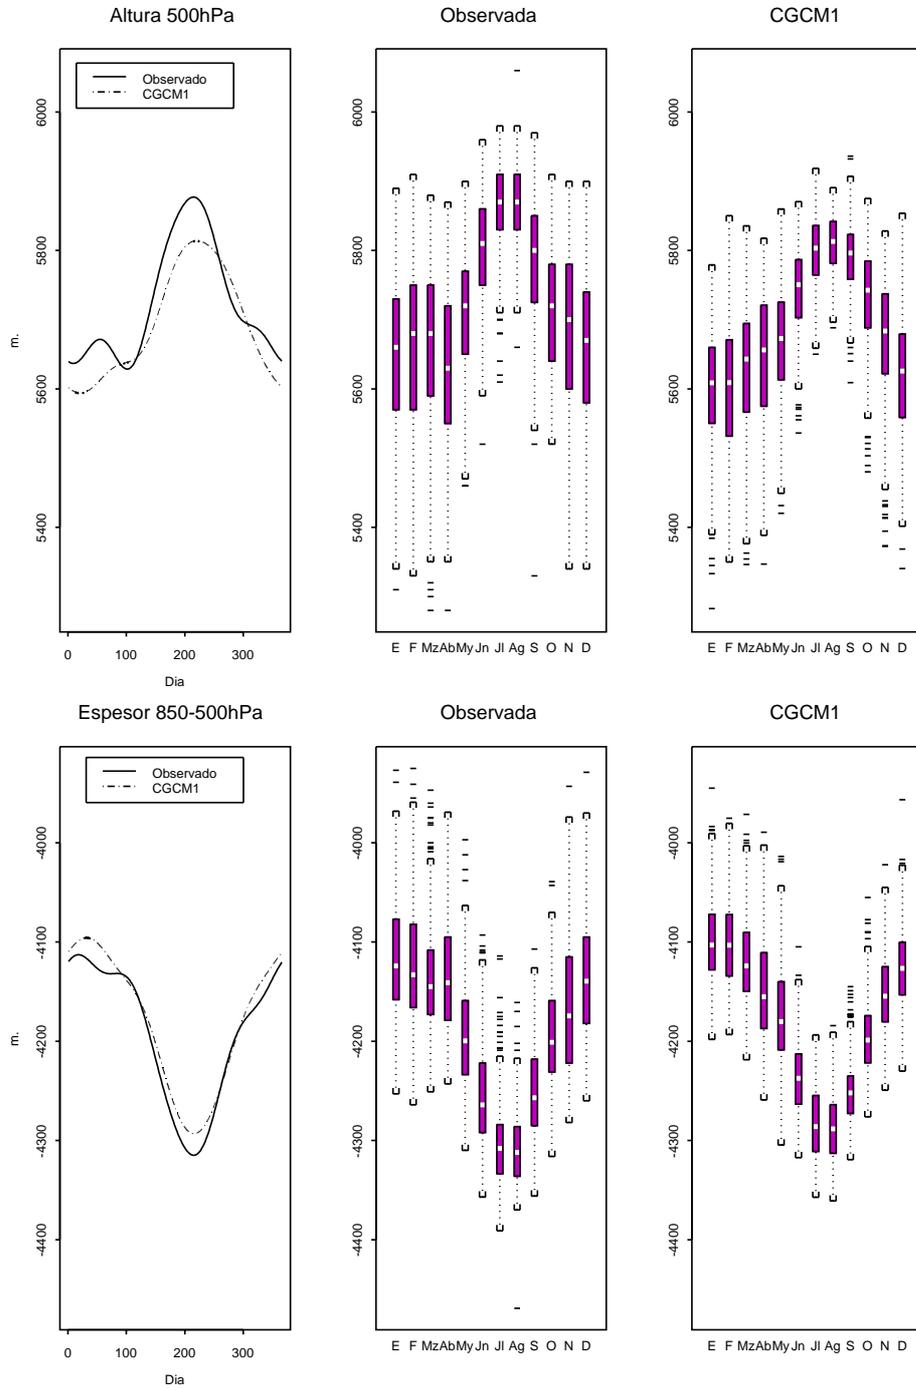


Figura 5.8: Altura del geopotencial 500hPa y espesor de la capa 850-500hPa, periodo 1990-2000. Suavizados y diagramas de caja por meses.

## Viento

- Las características del viento simulado no corresponden con las observadas en Zaragoza; las discrepancias son mayores en superficie y disminuyen si nos elevamos en altura.
- En Zaragoza, en superficie, dominan los vientos de componente NW y, en menor medida, los de SE. Los datos simulados están lejos de reflejar esa situación ya que las frecuencias de los vientos de procedencias entre SW y NW son similares, mientras que los vientos de SE no tienen una incidencia especial, ver figura 5.9.
- En 850hPa existe todavía un predominio de la procedencia NW en el viento observado que desaparece en 500hPa, ver figura 5.9. En el régimen simulado la frecuencia de los vientos de procedencia W es mayor cuanto más alto es el nivel, por lo que en 500hPa las dos distribuciones muestran menos diferencias, aunque no se pueden considerar análogas.
- La velocidad del viento en superficie en Zaragoza es mayor que la que proponen los valores simulados, ver figura 5.10. Las discrepancias se producen también en el nivel 850hPa y en 500hPa, ver figura 5.10 inferior.
- La comparación de las distribuciones de las componentes U y V del viento por meses, ver figuras 5.11 a 5.13, produce una visión complementaria a la señalada:
  - En superficie y para las dos componentes, los suavizados y la amplitud de las cajas de ambos conjuntos de datos son distintos. El nivel medio de la componente U es muy diferente en los meses de Verano, cuando CGCM1 dejaría de señalar el predominio de vientos con procedencia Oeste. El paralelismo de los suavizados de la componente V indica una discrepancia persistente a lo largo de todo el año.
  - En los dos niveles geopotenciales, el perfil medio de las componentes se asemeja entre Abril y Octubre, algo menos en la componente V en 850hPa; la discrepancia en los meses más fríos se debe a un mayor predominio en los datos simulados de las procedencias Oeste y Sur.  
La amplitud de las cajas, particularmente en la componente V, es similar en términos generales.

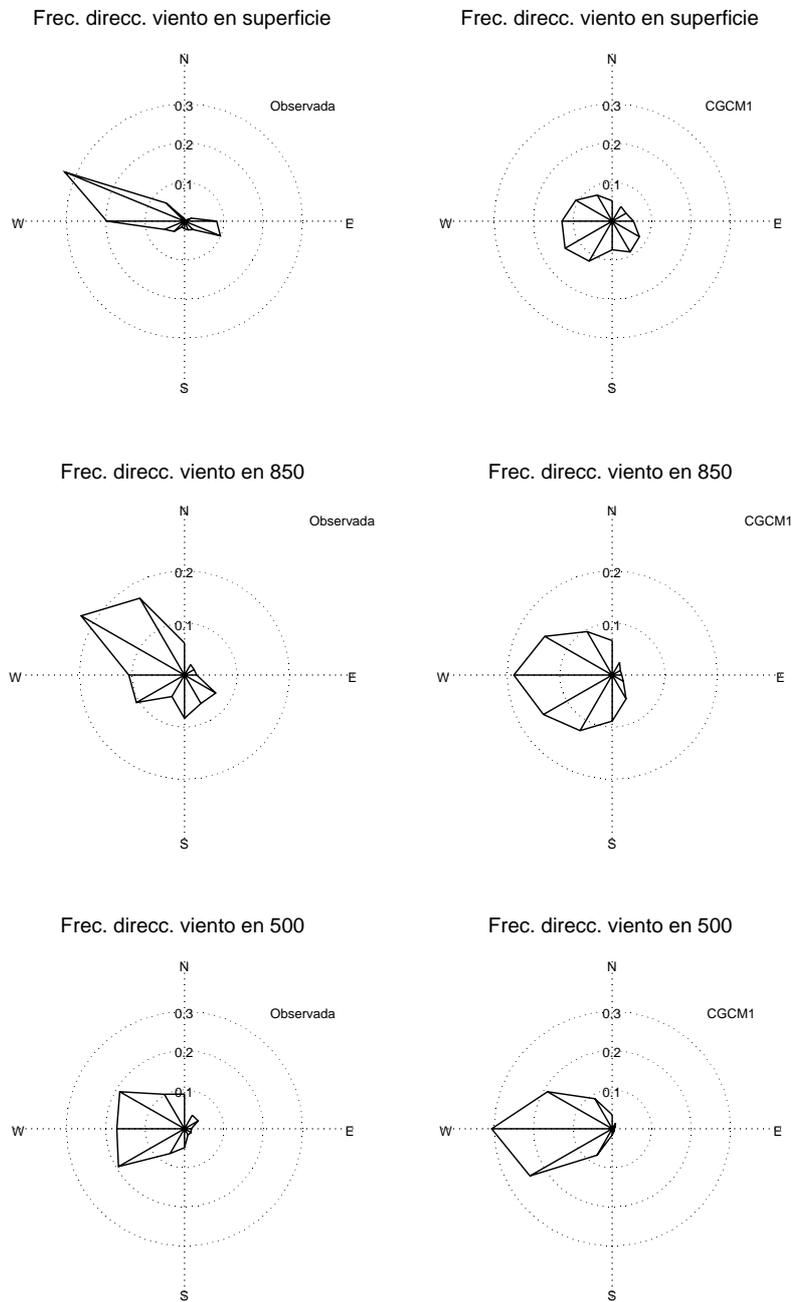


Figura 5.9: Rosas de viento con la frecuencia de las direcciones observadas y simuladas, periodo 1990-2000.

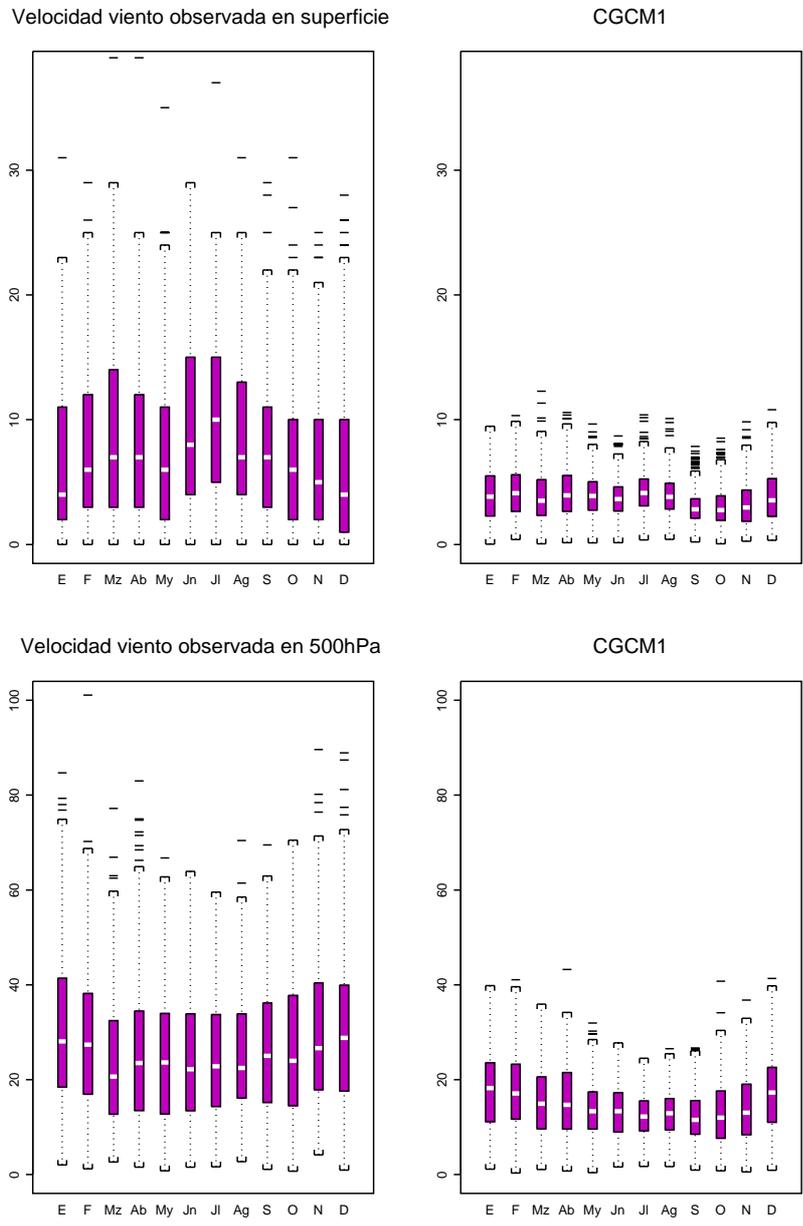


Figura 5.10: Diagramas de caja por meses de la velocidad del viento en superficie y en 500hPa, observada y simulada, periodo 1990-2000.

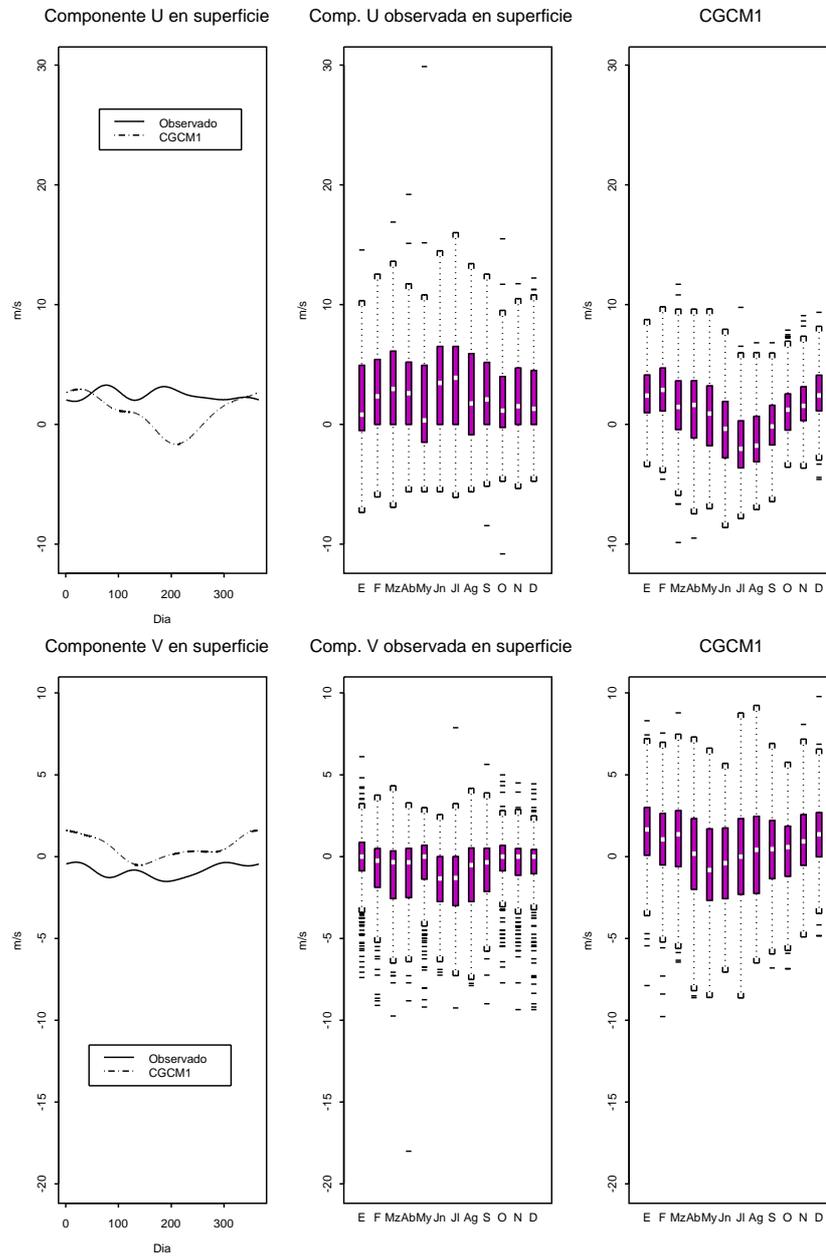


Figura 5.11: Componentes de viento en superficie, periodo 1990-2000. Suavizados y diagramas de caja por meses.

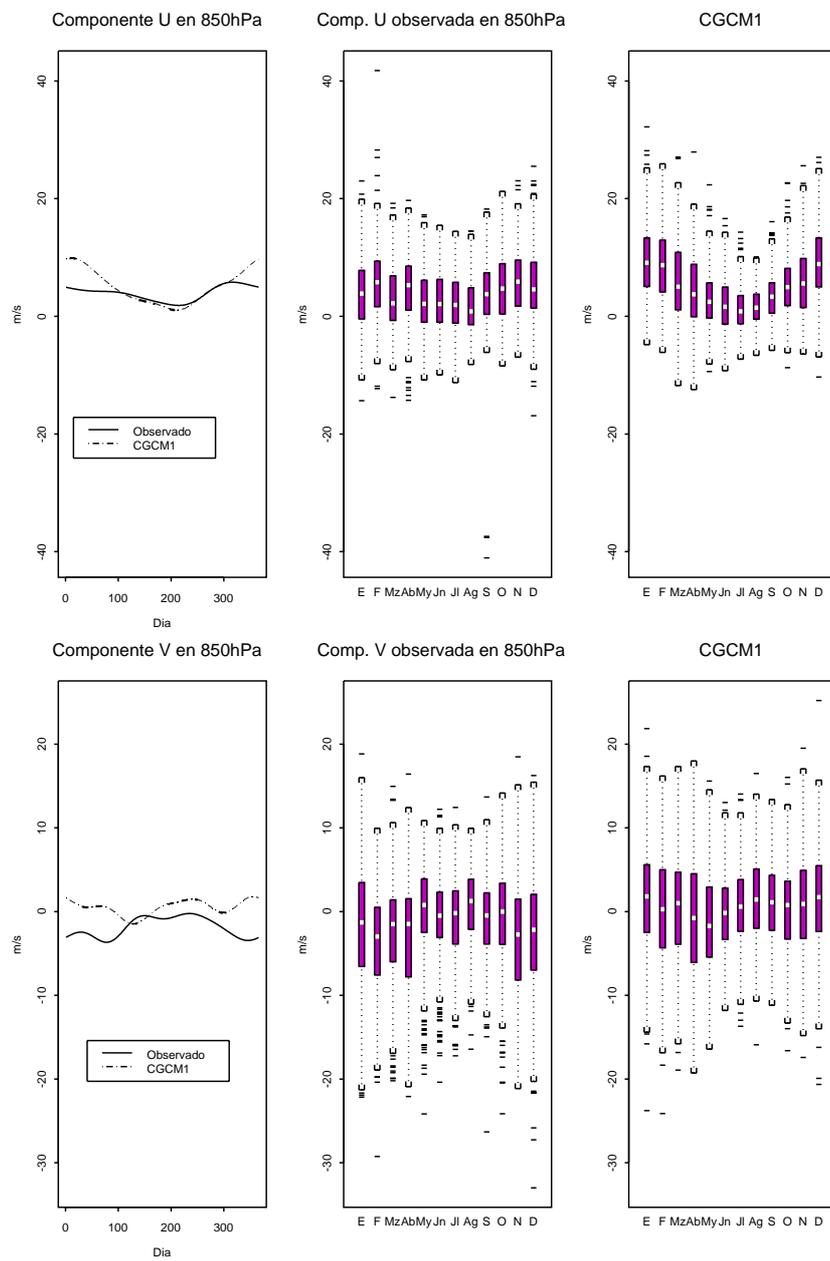


Figura 5.12: Componentes de viento en 850hPa, periodo 1990-2000. Suavizados y diagramas de caja por meses.

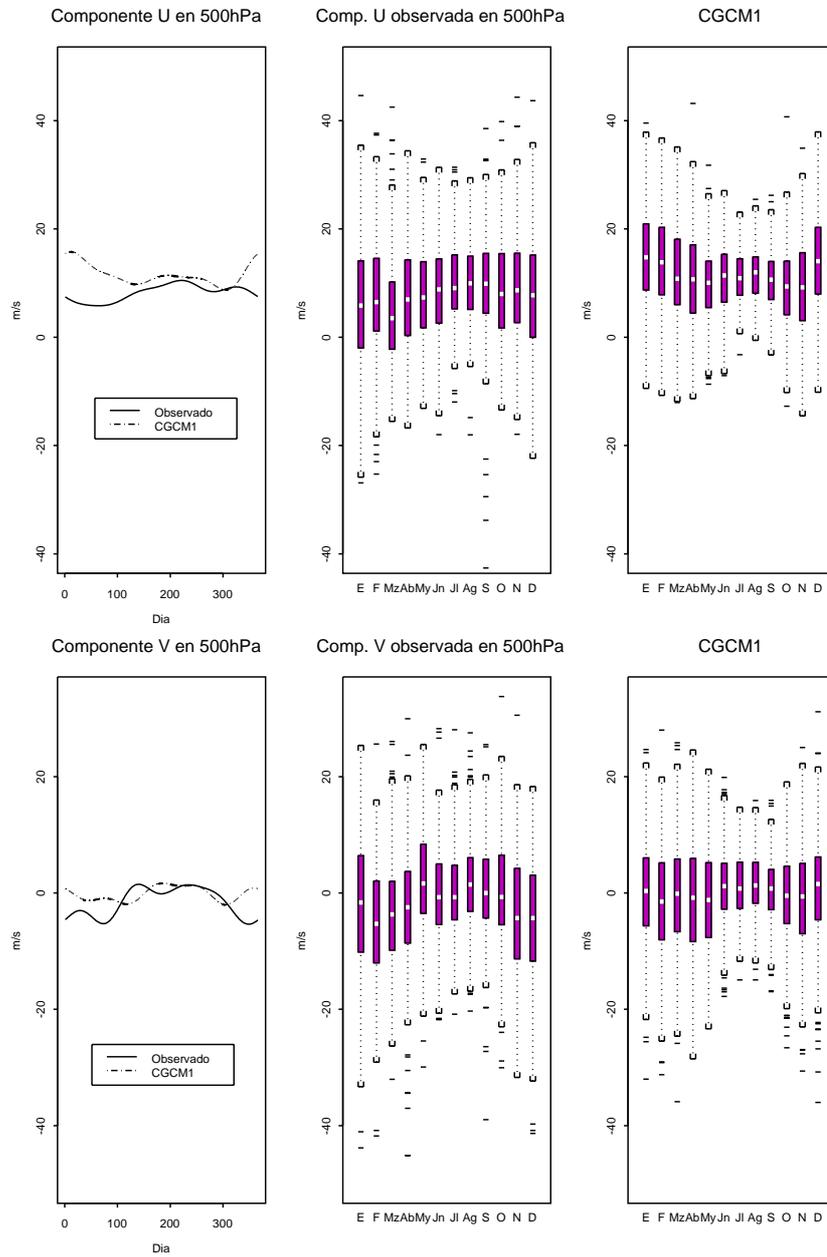


Figura 5.13: Componentes de viento en 500hPa, periodo 1990-2000. Suavizados y diagramas de caja por meses.

### Contrastes para comparar las distribuciones

El análisis descriptivo anterior ha establecido, como era de esperar, que la mayoría de las variables generadas por CGCM1 para la celda que contiene a Zaragoza, no reproducen el comportamiento que tienen en dicho observatorio. Ese análisis se completa ahora con un estudio de los p-valores resultantes en algunos contrastes de hipótesis que comparan, en cada mes, la distribución, o aspectos de ella, para los datos observados y simulados. El objetivo es decidir qué variables, o anomalías, medidas en Zaragoza se pueden considerar bien representadas por los valores generados por el GCM para el conjunto de la celda.

Para cada variable o anomalía se ha realizado: un contraste de tipo t sobre la igualdad de medias, un test de Wilcoxon sobre la igualdad de medianas, un test F sobre la igualdad de varianzas, un test de Wilcoxon aplicado a las distancias de los datos a su media y, finalmente, un test KS para contrastar la igualdad de distribuciones. En las tablas C.4-C.11 se pueden consultar los p-valores resultantes al aplicar esos contrastes; una síntesis se puede ver en la tabla 5.3.

Los dos conjuntos de datos, observado y simulado, no constituyen una muestra aleatoria simple sino que tienen dependencia serial. De los tests utilizados sólo el de tipo t tiene en cuenta la autocorrelación en los días consecutivos, de modo que los p-valores resultantes en los demás deben utilizarse como medidas de la distancia entre las distribuciones de unas muestras que tienen, aproximadamente, 300 datos.

La tabla 5.3 contiene el número de meses en los que se obtiene un p-valor menor que 0.01 y 0.05 en cada test. Al analizar la tabla observamos que refleja resultados ya señalados en el análisis descriptivo:

- Las discrepancias en la representación de las variables se deben, en buena parte, a diferencias en la localización de la distribución o en la reproducción del ciclo estacional; por ese motivo los tests de posición central aplicados producen un gran número de p-valores menores que 0.01.

Cuatro variables analizadas,  $T_{850.00}$ ,  $Q_{500.00}$ ,  $U_{850.00}$  y  $V_{500.00}$ , presentan p-valores mayores que 0.05 en el test t en la mitad, al menos, de los meses.

Al comparar la dispersión y, mediante el test KS, la distribución global, sólo los p-valores correspondientes a  $Q_{500.00}$  superan el umbral 0.05

	Test t	Wilcoxon	Test F	Dispers.	KS
<i>TMAX</i>	9/11	12/12	10/11	10/10	12/12
<i>TMIN</i>	6/7	7/10	7/9	6/6	11/12
<i>TDIF</i>	10/10	10/10	8/9	5/7	10/10
<i>T850.00</i>	2/5	6/7	8/8	9/11	11/11
<i>T500.00</i>	6/12	9/11	11/11	9/9	11/12
<i>T85/50.00</i>	6/8	9/9	6/8	7/8	10/11
<i>QSUP</i>	12/12	12/12	1/2	1/1	12/12
<i>Q850.00</i>	9/10	10/10	6/8	5/8	9/11
<i>Q500.00</i>	1/2	3/4	4/5	1/3	2/4
<i>PSUP</i>	9/9	11/11	5/6	4/5	9/11
<i>A850.00</i>	7/8	9/9	2/3	2/2	9/9
<i>A500.00</i>	7/8	8/9	12/12	8/12	11/12
<i>A85/50.00</i>	4/8	10/10	9/11	7/8	11/11
<i>USUP</i>	6/7	7/9	11/11	10/11	11/12
<i>VSUP</i>	11/11	11/11	5/5	6/6	12/12
<i>U850.00</i>	4/5	6/6	4/6	5/6	6/7
<i>V850.00</i>	8/9	9/10	4/6	0/2	10/10
<i>U500.00</i>	4/7	8/9	10/10	8/8	10/11
<i>V500.00</i>	4/6	6/8	7/9	5/8	8/9
<i>z.TMAX</i>	0/0	0/1	10/10	10/11	9/10
<i>z.TMIN</i>	0/0	0/1	8/9	7/8	6/6
<i>z.TDIF</i>	0/0	0/1	8/9	5/7	0/5
<i>z.T850.00</i>	0/0	1/1	9/10	11/11	8/9
<i>z.T500.00</i>	0/0	0/2	11/11	9/10	3/6
<i>z.T85/50.00</i>	0/0	0/1	6/8	7/8	2/6
<i>z.QSUP</i>	0/1	3/3	2/2	1/2	1/3
<i>z.Q850.00</i>	0/0	0/0	7/8	6/8	0/2
<i>z.Q500.00</i>	0/0	0/0	4/5	1/3	0/1
<i>z.PSUP</i>	0/0	0/0	4/6	4/5	1/3
<i>z.A850.00</i>	0/0	0/0	2/3	1/2	0/0
<i>z.A500.00</i>	0/0	0/0	11/11	10/10	3/8
<i>z.A85/50.00</i>	0/0	2/3	9/11	7/8	7/8
<i>z.USUP</i>	0/0	0/2	11/11	11/11	8/9
<i>z.VSUP</i>	0/0	0/2	5/5	6/6	7/8
<i>z.U850.00</i>	0/0	0/2	5/6	5/6	2/3
<i>z.V850.00</i>	0/0	1/3	4/6	0/2	2/3
<i>z.U500.00</i>	0/0	0/0	10/10	8/8	3/7
<i>z.V500.00</i>	0/0	0/0	7/9	5/8	0/1

Tabla 5.3: Resultados de los tests que comparan la distribución, por meses, de los datos diarios observados y simulados por CGCM1 para 1990-2000. Se señala con  $n/m$  el número de meses donde el p-valor es menor que 0.01 ( $n$ ) o 0.05 ( $m$ ).

en más de la mitad de los meses. En la componente  $U850.00$ , el test KS produce p-valores mayores que 0.01 en la mitad de los meses del año.

- Los tests relativos a la posición central de las anomalías no producen, en general, p-valores menores que 0.05, lo que indica que el nivel medio ha sido retirado de forma adecuada. Al comparar los p-valores del test KS cuando se aplica a las variables y a sus anomalías, comprobamos que las distribuciones de estas últimas son más próximas en ambos conjuntos.

El test KS produce un menor número de p-valores inferiores a 0.01 que los tests F y de Wilcoxon para comparar la dispersión, lo que se explica por la mayor sensibilidad de éstos a la presencia de puntos extremos.

Las anomalías con un p-valor mayor que 0.05 en la mitad de los meses en los contrastes KS y F son:  $z.QSUP$ ,  $z.Q500.00$ ,  $z.PSUP$ ,  $z.A850.00$ ,  $z.U850.00$  y  $z.V850.00$ ; éstas son las variables con una reproducción más adecuada de los valores observados. Por el contrario, el test KS produce p-valores menores que 0.01 en más de la mitad de los meses en  $z.TMAX$ ,  $z.T850.00$ ,  $z.A85/50.00$  y las anomalías de las componentes de viento en superficie; éstas serían, a su vez, las variables con un comportamiento más discrepante.

A continuación se hace un análisis de cómo se producen las discrepancias a lo largo del año, al objeto de reconocer las épocas en las que las distribuciones son similares o discrepan. Para ello se muestran en las tablas 5.4 y 5.5 los resultados de los tests KS y F, respectivamente, indicando el número de meses en el año, y en cada estación, en los que el p-valor es menor que 0.01 y 0.05. Al analizar esas tablas vemos que:

- La variabilidad de  $Q500.00$  es diferente en los meses de Primavera; en las otras tres estaciones los datos simulados se comportan como los observados.

$U850.00$  tiene en el test KS un p-valor mayor que 0.05 en dos meses de Primavera y en dos de los de Otoño. En esta última estación el test F indica una discrepancia al 5% en dos de los meses.

Para el resto de las variables, el test KS produce p-valores menores que 0.05 en la mayoría de los meses de cada estación.

- En cuanto a las anomalías:

- En  $z.PSUP$ ,  $z.A850.00$  y en las anomalías de humedad y de la componente V del viento en las dos alturas consideradas, el test KS produce un p-valor menor que 0.05 en, a lo sumo, un mes, en cada una de las cuatro estaciones.  
Como ya comentamos, la situación no resulta tan satisfactoria cuando se compara específicamente la dispersión; el test F produce un p-valor mayor que 0.05 en la mayoría de los meses, en tres estaciones, en  $z.A850.00$  y  $z.Q500.00$ , en dos, en  $z.V850.00$  y  $z.PSUP$  y, en una, en  $z.Q850.00$  y  $z.V500.00$ .
- En  $z.QSUP$  los tests F y KS producen p-valores mayores que 0.05 en dos o tres meses de cada estación, en todas las estaciones salvo en Primavera.  
En  $z.U850.00$  los p-valores del test KS son mayores que 0.05 en la mayoría de los meses de tres estaciones, entre ellas Invierno y Primavera. En estas dos se verifica ese criterio también con el test F.
- En  $z.TMIN$ ,  $z.TDIF$ ,  $z.T500.00$ ,  $z.A500.00$ ,  $z.T85/50.00$ ,  $z.VSUP$  y  $z.U500.00$  el test KS produce un p-valor mayor que 0.05 en la mayoría de los meses, en dos estaciones.
- El mayor grado de discrepancia se observa en  $z.TMAX$  y  $z.USUP$ , que tienen en el test KS un p-valor menor que 0.05, en al menos dos de los meses, en todas las estaciones. En  $z.T850.00$  y  $z.A85/50.00$  esto ocurre en tres de ellas.

Para completar este estudio se ha aplicado un test en el que la hipótesis nula establece la igualdad de la distribución observada con la de los datos generados por CGCM1. Para realizarlo se efectúa un test de comparación en cada uno de los meses. Como estos tests no pueden considerarse independientes, puesto que los datos de los meses próximos están afectados por una común situación climática, para establecer la conclusión se ha utilizado un esquema seguido por von Storch y Zwiers (1999) [113] para aplicar un test global sobre una región basándose en varios tests locales.

La fracción de rechazo que se produce en los 12 tests aplicados a los meses, con un nivel de significación fijado, se utiliza para identificar el número de tests independientes en los que esa fracción de rechazos permitiría aceptar la hipótesis nula global, ver tabla 5.6. Si se considera que se dispone de ese número de tests independientes, o de un número menor, se acepta la hipótesis nula.

	Global	Invierno	Primavera	Verano	Otoño
<i>TDIF</i>	10/10	2/2	3/3	2/2	3/3
<i>PSUP</i>	9/11	0/2	3/3	3/3	3/3
<i>A850.00</i>	9/9	3/3	2/2	3/3	2/2
<i>Q850.00</i>	9/11	0/2	3/3	3/3	3/3
<i>Q500.00</i>	2/4	0/1	2/2	0/1	0/0
<i>T85/50.00</i>	10/11	1/2	3/3	3/3	3/3
<i>U850.00</i>	6/7	3/3	1/1	1/2	1/1
<i>V850.00</i>	10/10	3/3	3/3	2/2	2/2
<i>U500.00</i>	10/11	3/3	3/3	3/3	1/2
<i>V500.00</i>	8/9	3/3	2/2	2/2	1/2
<i>z.TMAX</i>	9/10	3/3	3/3	2/2	1/2
<i>z.TMIN</i>	6/6	0/0	1/1	2/2	3/3
<i>z.TDIF</i>	0/5	0/0	0/3	0/0	0/2
<i>z.PSUP</i>	1/3	0/0	1/1	0/1	0/1
<i>z.QSUP</i>	1/3	0/0	1/2	0/0	0/1
<i>z.T850.00</i>	8/9	2/3	3/3	2/2	1/1
<i>z.A850.00</i>	0/0	0/0	0/0	0/0	0/0
<i>z.Q850.00</i>	0/2	0/0	0/1	0/0	0/1
<i>z.T500.00</i>	3/6	1/2	0/1	0/1	2/2
<i>z.A500.00</i>	3/8	1/3	0/1	0/1	2/3
<i>z.Q500.00</i>	0/1	0/0	0/1	0/0	0/0
<i>z.T85/50.00</i>	2/6	0/0	0/1	1/3	1/2
<i>z.A85/50.00</i>	7/8	2/3	2/2	0/0	3/3
<i>z.USUP</i>	8/9	2/2	1/2	2/2	3/3
<i>z.VSUP</i>	7/8	2/3	1/1	3/3	1/1
<i>z.U850.00</i>	2/3	0/0	0/0	1/2	1/1
<i>z.V850.00</i>	2/3	0/0	1/1	1/1	0/1
<i>z.U500.00</i>	3/7	0/1	1/2	1/3	1/1
<i>z.V500.00</i>	0/1	0/1	0/0	0/0	0/0

Tabla 5.4: Resultados global y por estaciones del test KS para comparar la distribución, por meses, de los datos diarios observados y simulados por CGCM1 para 1990-2000.

	Global	Invierno	Primavera	Verano	Otoño
<i>TMAX</i>	10/11	3/3	3/3	2/3	2/2
<i>TMIN</i>	7/9	0/0	1/3	3/3	3/3
<i>TDIF</i>	8/9	2/2	3/3	1/2	2/2
<i>PSUP</i>	5/6	0/0	1/1	3/3	1/2
<i>QSUP</i>	1/2	0/0	1/1	0/1	0/0
<i>T850.00</i>	8/8	3/3	2/2	2/2	1/1
<i>A850.00</i>	2/3	0/0	0/1	0/0	2/2
<i>Q850.00</i>	6/8	2/3	2/3	0/0	2/2
<i>Q500.00</i>	4/5	0/1	3/3	1/1	0/0
<i>T85/50.00</i>	6/8	3/3	0/2	1/1	2/2
<i>A85/50.00</i>	9/11	3/3	1/2	2/3	3/3
<i>VSUP</i>	5/5	0/0	1/1	3/3	1/1
<i>U850.00</i>	4/6	0/0	1/1	2/3	1/2
<i>V850.00</i>	4/6	2/2	0/0	0/1	2/3
<i>U500.00</i>	10/10	3/3	1/1	3/3	3/3
<i>V500.00</i>	7/9	2/3	0/0	3/3	3/3
<i>z.TMAX</i>	10/10	3/3	3/3	2/2	2/2
<i>z.TMIN</i>	8/9	0/0	2/3	3/3	3/3
<i>z.TDIF</i>	8/9	2/2	3/3	1/1	2/3
<i>z.PSUP</i>	4/6	0/0	1/1	3/3	0/2
<i>z.QSUP</i>	2/2	0/0	1/1	1/1	0/0
<i>z.T850.00</i>	9/10	3/3	2/3	2/2	2/2
<i>z.A850.00</i>	2/3	0/0	0/1	0/0	2/2
<i>z.Q850.00</i>	7/8	2/3	3/3	0/0	2/2
<i>z.T500.00</i>	11/11	3/3	2/2	3/3	3/3
<i>z.A500.00</i>	11/11	3/3	2/2	3/3	3/3
<i>z.Q500.00</i>	4/5	0/1	3/3	1/1	0/0
<i>z.T85/50.00</i>	6/8	3/3	0/2	1/1	2/2
<i>z.A85/50.00</i>	9/11	3/3	1/2	2/3	3/3
<i>z.USUP</i>	11/11	3/3	2/2	3/3	3/3
<i>z.VSUP</i>	5/5	0/0	1/1	3/3	1/1
<i>z.U850.00</i>	5/6	0/0	1/1	2/3	2/2
<i>z.V850.00</i>	4/6	2/2	0/0	0/1	2/3
<i>z.U500.00</i>	10/10	3/3	1/1	3/3	3/3
<i>z.V500.00</i>	7/9	1/3	0/0	3/3	3/3

Tabla 5.5: Resultados global y por estaciones del test F para comparar, por meses, la varianza de los datos diarios observados y simulados por CGCM1 para 1990-2000.

Número de rechazos	$\alpha=0.05$ $\alpha^G=0.05$	$\alpha=0.01$ $\alpha^G=0.05$	$\alpha=0.05$ $\alpha^G=0.01$	$\alpha=0.01$ $\alpha^G=0.01$
1	130	7	269	21
2	13	1	28	6
3	5	0	11	4
4 (fracción de rechazo=1/3)	3	0	6	3
5	2	0	3	2
6	2	0	3	2
7	1	0	1	1
8 (fracción de rechazo=2/3)	1	0	1	1
9	1	0	1	1
10	1	0	1	1
11	1	0	1	1
12	1	0	1	1

Tabla 5.6: Número de tests independientes con los que se aceptaría la hipótesis nula global, con nivel de significación  $\alpha^G$ , dada esa frecuencia relativa de rechazo en los tests locales, con nivel de significación  $\alpha$ .

La regla de decisión depende de los niveles de significación establecidos. Atendiendo a la información de la tabla 5.6, la conclusión del test global será la siguiente:

- Fijando  $\alpha = 0.05 = \alpha^G$ , se admiten hasta 2 rechazos entre los 12 tests sin que se rechace la hipótesis nula de una correcta representación, dado que el número de tests independientes es menor que 13.
- Con  $\alpha = 0.01$  y  $\alpha^G = 0.05$  no se admite ningún rechazo.
- Con  $\alpha = 0.05$  y  $\alpha^G = 0.01$  se admiten hasta 3 rechazos.
- Con  $\alpha = 0.01$  y  $\alpha^G = 0.01$  se admite un rechazo en los doce tests mensuales.

Los resultados de este contraste global se muestran en la tabla 5.7. Para cada nivel de significación, se indica con una letra G las variables para las que se acepta la hipótesis nula cuando se aplica el test KS o el test F. Las conclusiones que se extraen son:

- Las anomalías que se pueden considerar bien representadas, según el test KS y para alguno de los niveles de significación, son:
  - las de humedad en las tres alturas,

Variable	$\alpha=0.05$ $\alpha^G=0.05$		$\alpha=0.01$ $\alpha^G=0.05$		$\alpha=0.05$ $\alpha^G=0.01$		$\alpha=0.01$ $\alpha^G=0.01$	
	KS	F	KS	F	KS	F	KS	F
<i>z.A850.00</i>	G	i,p,v	G	i,p,v	G	G	G	i,p,v
<i>z.Q850.00</i>	G	v	G	v	G	v	G	v
<i>z.Q500.00</i>	G	i,v,o	G	i,o	G	i,v,o	G	i,v,o
<i>z.V500.00</i>	G	p	G	p	G	p	G	i,p
<i>z.PSUP</i>	i,p,v,o	i,p	i,v,o	i,o	G	i,p	G	i,p,o
<i>z.QSUP</i>	i,v,o	G	i,v,o	i,o	G	G	G	i,p,v,o
<i>z.TDIF</i>	i,v	v	G		i,v	v	G	v
<i>z.U850.00</i>	i,p,o	i,p	i,p	i	G	i,p	i,p,v,o	i,p
<i>z.V850.00</i>	i,p,v,o	p,v	i,o	p,v	G	p,v	i,p,v,o	p,v
<i>z.TMIN</i>	i,p	i	i	i	i,p	i	i,p	i
<i>z.T850.00</i>	o				o		o	
<i>z.T500.00</i>	p,v		p,v		p,v		i,p,v	
<i>z.A500.00</i>	p,v		p,v		p,v		i,p,v	
<i>z.T85/50.00</i>	i,p	v	i,p	p	i,p	v	i,p,v,o	p,v
<i>z.A85/50.00</i>	v		v		v		v	p
<i>z.USUP</i>							p	
<i>z.VSUP</i>	p,o	i,p,o		i	p,o	i,p,o	p,o	i,p,o
<i>z.U500.00</i>	i,o	p	i		i,o	p	i,p,v,o	p
<i>TMIN</i>		i		i		i		i,p
<i>TDIF</i>								v
<i>PSUP</i>		i,p	i	i		i,p	i	i,p,o
<i>QSUP</i>		G		i,v,o		G		G
<i>T850.00</i>		o				o		o
<i>A850.00</i>		i,p,v		i,p,v		G		i,p,v
<i>Q850.00</i>		v	i	v		v	i	v
<i>Q500.00</i>	i,v,o	i,v,o	i,v,o	i,o	i,v,o	i,v,o	i,v,o	i,v,o
<i>T85/50.00</i>		v		p		v	i	p,v
<i>VSUP</i>		i,p,o		i		i,p,o		i,p,o
<i>U850.00</i>	p,o	i,p		i	p,o	i,p	p,v,o	i,p,o
<i>V850.00</i>		p,v		p,v		p,v		p,v
<i>U500.00</i>		p				p	o	p
<i>V500.00</i>		p		p		p	o	p

Tabla 5.7: Resultado del test global para evaluar la reproducción correcta de variables y anomalías. Se señalan, con la letra G, las variables para las que no se rechaza una reproducción correcta y, con su letra inicial, las estaciones en las que no se rechaza el test global correspondiente.

- las de presión y rango de temperatura en superficie,
- las de altura del geopotencial 850hPa,
- las de las dos componentes del viento en 850hPa y de la componente V en 500hPa.

Con el test F sólo se aceptaría la igualdad de varianzas en  $z.A850.00$  y en  $z.QSUP$ , utilizando en ambos casos  $\alpha = 0.05$  pero distinto nivel global.

- Se rechaza la hipótesis de igualdad de distribución en todas las variables.

Si se lleva a cabo este análisis para rechazar o aceptar la reproducción de una variable, o anomalía, en una estación, el test se basará, en cada caso, en 3 tests mensuales. De acuerdo con la tabla 5.6 se admite la hipótesis nula cuando se produce un rechazo individual tanto con  $\alpha = 0.01$  y  $\alpha^G = 0.01$  como con nivel  $\alpha = 0.05$ . Los resultados de este análisis con el test KS y con  $\alpha = 0.01$  y  $\alpha^G = 0.01$ , ver tabla 5.7, señalan que hay anomalías cuya reproducción no se considera correcta globalmente que sí son reproducidas adecuadamente en dos o más estaciones; las excepciones a esta situación son  $z.T850.00$ ,  $z.A85/50.00$  y  $z.USUP$ . En el caso de las variables  $Q500.00$  y  $U850.00$ , no se rechaza la hipótesis de igualdad en tres de las cuatro estaciones; en las demás variables esto sólo ocurre en una o en ninguna estación.

### Análisis comparativo de la estructura de autocorrelación

Para analizar la reproducción de la estructura de dependencia temporal se han comparado las autocorrelaciones de orden 1 y 2 de las variables observadas y simuladas, ver tabla 5.8. El análisis de estos estadísticos para las anomalías permite valorar si la estructura de dependencia serial está bien reproducida en la simulación de CGCM1, una vez descontado el efecto estacional que muestran la mayoría de las variables. Como conclusión se puede establecer:

- La serie observada de  $Q850.00$  y la de sus anomalías presentan mayor grado de dependencia que las correspondientes de CGCM1, mientras que la situación contraria se produce en  $T85/50.00$ , siendo más pronunciada aún la diferencia en sus anomalías.

La serie diaria simulada de la componente U del viento en las tres alturas presenta mayor grado de dependencia que la de los datos observados; lo mismo ocurre con la serie de las anomalías.

Variable	Datos				Anomalías			
	$\hat{\rho}_1$		$\hat{\rho}_2$		$\hat{\rho}_1$		$\hat{\rho}_2$	
	Obs.	Simul.	Obs.	Simul.	Obs.	Simul.	Obs.	Simul.
<i>TMAX</i>	0.93	0.95	0.88	0.91	0.67	0.7	0.41	0.45
<i>TMIN</i>	0.92	0.86	0.87	0.75	0.62	0.65	0.35	0.36
<i>TDIF</i>	0.57	0.73	0.41	0.59	0.4	0.49	0.18	0.22
<i>PSUP</i>	0.84	0.81	0.62	0.56	0.81	0.78	0.56	0.5
<i>QSUP</i>	0.85	0.8	0.76	0.61	0.64	0.64	0.4	0.28
<i>T850.00</i>	0.87	0.9	0.78	0.8	0.65	0.67	0.4	0.37
<i>A850.00</i>	0.83	0.82	0.61	0.59	0.8	0.8	0.57	0.56
<i>Q850.00</i>	0.84	0.57	0.76	0.35	0.54	0.39	0.3	0.08
<i>T500.00</i>	0.83	0.89	0.72	0.81	0.6	0.62	0.35	0.33
<i>A500.00</i>	0.88	0.9	0.74	0.78	0.79	0.8	0.54	0.55
<i>Q500.00</i>	0.49	0.47	0.41	0.32	0.22	0.26	0.1	0.07
<i>T85/50.00</i>	0.5	0.66	0.3	0.39	0.39	0.61	0.14	0.31
<i>A85/50.00</i>	0.88	0.91	0.78	0.83	0.68	0.65	0.43	0.36
<i>USUP</i>	0.5	0.7	0.24	0.47	0.49	0.62	0.23	0.32
<i>VSUP</i>	0.5	0.52	0.28	0.21	0.49	0.49	0.26	0.17
<i>U850.00</i>	0.53	0.7	0.34	0.53	0.51	0.62	0.31	0.39
<i>V850.00</i>	0.48	0.54	0.26	0.29	0.45	0.52	0.23	0.27
<i>U500.00</i>	0.58	0.71	0.4	0.49	0.57	0.69	0.39	0.46
<i>V500.00</i>	0.52	0.51	0.27	0.23	0.49	0.5	0.22	0.21

Tabla 5.8: Autocorrelaciones de orden 1 y 2 de las variables observadas y generadas por CGCM1 para el periodo 1990-2000.

Las discrepancias que se observan en las autocorrelaciones de  $TDIF$  se corrigen, en parte, en su serie de anomalías.

- Los coeficientes de autocorrelación de las series de anomalías simuladas son, en general, semejantes a los de las series observadas.

Los coeficientes de orden 1 se diferencian en cantidades poco relevantes, salvo en  $z.Q500.00$ , donde el cambio supone un 20% del coeficiente observado, y en las variables citadas en el apartado anterior.

En el coeficiente de orden 2 las diferencias son inferiores al 15% del valor observado en la mayoría de los casos; las mayores diferencias se producen en las anomalías de las tres variables de humedad y en  $z.T85/50.00$ .

Para contrastar si la estructura de dependencia de la serie simulada por CGCM1 es análoga a la de la observada, se ha construido, en cada estación, el periodograma ‘chunk’ (von Storch y Zwiers (1999) [113], pag. 270). Para cada anomalía y en cada estación del año, se obtiene el periodograma de la subserie correspondiente a cada año, de modo que se tienen tantas réplicas como años disponibles. A partir de los periodogramas, se calcula la intensidad media correspondiente a cada frecuencia y se construye una banda de confianza basada en el comportamiento chi-cuadrado del cociente entre el estimador y la intensidad. Sobre ese gráfico se superpone la correspondiente estimación del espectro de la variable simulada, con el fin de comprobar si se encuentra dentro de la banda.

Los periodogramas de  $z.A500.00$  y de  $z.T85/50.00$ , dos variables que, respectivamente, mostraban semejanza y discrepancia en los dos primeros coeficientes de autocorrelación, se muestran en las figuras 5.14 y 5.15. No se rechaza la igualdad del espectro de las anomalías observadas y simuladas, salvo en el periodograma de  $z.A500.00$  en Otoño, donde el obtenido a partir de los datos del GCM se sitúa por debajo del límite inferior.

### **Comparación de la estructura de correlación entre variables**

En la tabla 5.9 se muestra la matriz de coeficientes de correlación entre las variables extraídas del GCM, para comparar si la asociación que muestran es análoga, tanto en signo como en magnitud, a la de las variables observadas. Si se exceptúan las variables de viento, hay similitud entre ambas matrices; en 54 de las 78 correlaciones existen diferencias menores de 0.15 entre los respectivos coeficientes y únicamente en 6 casos, 4 correspondientes a la altura del nivel geopotencial 850hPa y 2 a la presión en superficie, se encuentran

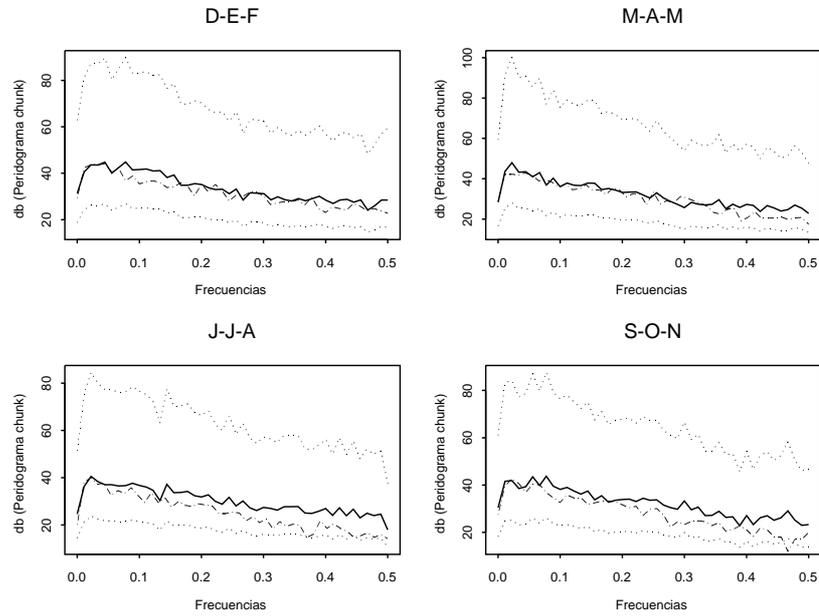


Figura 5.14: Espectros estacionales de  $z.A500.00$ , observada y generada por CGCM1 para 1990-2000. Se incluye una banda de confianza al 95%.

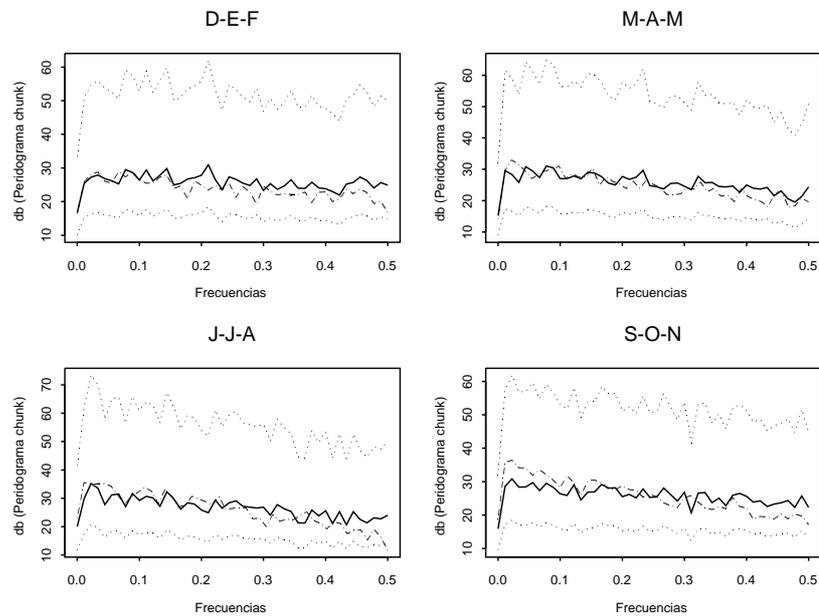


Figura 5.15: Espectros estacionales de  $z.T85/50.00$ , observada y generada por CGCM1 para 1990-2000.

signos contrarios. En cuanto a las componentes del viento, destacan las diferencias entre los coeficientes asociados a *USUP* y, en menor grado, de los asociados a las componentes U en las otras dos alturas geopotenciales.

Las matrices de los coeficientes de correlación correspondientes a las series de anomalías, ver tabla 5.10, muestran mayores diferencias. Hay 22 coeficientes de distinto signo, de los que 5 corresponden a *z.A850.00*, 5 a *z.Q850.00* y 8 a las componentes U del viento en las tres alturas. Entre los coeficientes que conservan el signo se observan algunas discrepancias aunque no de carácter sistemático, excepto en *z.QSUP* cuyos datos simulados muestran correlaciones más débiles.

<i>TMAX</i>	1	0.89	0.68	-0.17	0.76	0.87	0.32	0.83	0.77	0.71	0.56	0.44	-0.82	-0.06	-0.02	-0.18	0.21	0.09	0.17
<i>TMIN</i>	0.89	1	0.28	-0.3	0.85	0.82	0.17	0.88	0.74	0.61	0.62	0.4	-0.78	-0.03	-0.05	-0.14	0.2	0.16	0.25
<i>TDIF</i>	0.68	0.28	1	0.12	0.25	0.51	0.4	0.34	0.44	0.51	0.19	0.28	-0.48	-0.08	0.05	-0.17	0.11	-0.06	-0.04
<i>PSUP</i>	-0.17	-0.3	0.12	1	-0.24	-0.08	0.83	-0.23	0.04	0.41	-0.15	-0.21	-0.02	0.13	-0.13	-0.17	-0.23	-0.32	-0.36
<i>QSUP</i>	0.76	0.85	0.25	-0.24	1	0.78	0.21	0.85	0.69	0.6	0.6	0.4	-0.74	-0.22	0.11	-0.24	0.34	0.1	0.31
<i>T8500.00</i>	0.87	0.82	0.51	-0.08	0.78	1	0.42	0.87	0.84	0.83	0.61	0.57	-0.94	-0.17	0.07	-0.26	0.35	0.06	0.29
<i>A850.00</i>	0.32	0.17	0.4	0.83	0.21	0.42	1	0.24	0.47	0.81	0.19	0.07	-0.49	-0.01	-0.04	-0.29	-0.02	-0.24	-0.18
<i>Q850.00</i>	0.83	0.88	0.34	-0.23	0.85	0.87	0.24	1	0.76	0.67	0.63	0.46	-0.83	-0.2	0.09	-0.2	0.36	0.15	0.33
<i>T5000.00</i>	0.77	0.74	0.44	0.04	0.69	0.84	0.47	0.76	1	0.87	0.66	0.04	-0.96	-0.07	0.01	-0.13	0.19	0.14	0.09
<i>A500.00</i>	0.71	0.61	0.51	0.41	0.6	0.83	0.81	0.67	0.87	1	0.54	0.22	-0.91	-0.08	0	-0.27	0.17	-0.05	0.04
<i>Q500.00</i>	0.56	0.62	0.19	-0.15	0.6	0.61	0.19	0.63	0.66	0.54	1	0.13	-0.67	-0.12	0.06	-0.07	0.22	0.17	0.19
<i>T85/500.00</i>	0.44	0.4	0.28	-0.21	0.4	0.57	0.07	0.46	0.04	0.22	0.13	1	-0.28	-0.2	0.11	-0.27	0.37	-0.1	0.4
<i>A85/500.00</i>	-0.82	-0.78	-0.48	-0.02	-0.74	-0.94	-0.49	-0.83	-0.96	-0.91	-0.67	-0.28	1	0.11	-0.03	0.2	-0.26	-0.1	-0.19
<i>USUP</i>	-0.06	-0.03	-0.08	0.13	-0.22	-0.17	-0.01	-0.2	-0.07	-0.08	-0.12	-0.2	0.11	1	-0.71	0.29	-0.63	0	-0.43
<i>VSUP</i>	-0.02	-0.05	0.05	-0.13	0.11	0.07	-0.04	0.09	0.01	0	0.06	0.11	-0.03	-0.71	1	-0.09	0.54	0.1	0.39
<i>U850.00</i>	-0.18	-0.14	-0.17	-0.17	-0.24	-0.26	-0.29	-0.2	-0.13	-0.27	-0.07	-0.27	0.2	0.29	-0.09	1	-0.44	0.56	-0.26
<i>V850.00</i>	0.21	0.2	0.11	-0.23	0.34	0.35	-0.02	0.36	0.19	0.17	0.22	0.37	-0.26	-0.63	0.54	-0.44	1	-0.01	0.67
<i>U500.00</i>	0.09	0.16	-0.06	-0.32	0.1	0.06	-0.24	0.15	0.14	-0.05	0.17	-0.1	-0.1	0	0.1	0.56	-0.01	1	0.12
<i>V500.00</i>	0.17	0.25	-0.04	-0.36	0.31	0.29	-0.18	0.33	0.09	0.04	0.19	0.4	-0.19	-0.43	0.39	-0.26	0.67	0.12	1
<i>TMAX</i>	1	0.84	0.67	-0.29	0.69	0.93	0.19	0.57	0.82	0.73	0.54	0.5	-0.88	-0.49	0.06	-0.36	0.18	-0.1	0.24
<i>TMIN</i>	0.84	1	0.16	-0.41	0.73	0.79	-0.03	0.62	0.64	0.49	0.5	0.49	-0.71	-0.33	0.1	-0.24	0.14	0	0.26
<i>TDIF</i>	0.67	0.16	1	0.04	0.26	0.61	0.38	0.18	0.61	0.64	0.28	0.23	-0.63	-0.42	-0.03	-0.33	0.13	-0.19	0.09
<i>PSUP</i>	-0.29	-0.41	0.04	1	-0.3	-0.32	0.86	-0.45	-0.1	0.32	-0.36	-0.41	0.17	-0.03	-0.29	-0.27	-0.19	-0.37	-0.32
<i>QSUP</i>	0.69	0.73	0.26	-0.3	1	0.67	0.02	0.68	0.6	0.48	0.42	0.34	-0.65	-0.41	0.12	-0.27	0.15	-0.06	0.27
<i>T850.00</i>	0.93	0.79	0.61	-0.32	0.67	1	0.18	0.58	0.81	0.75	0.65	0.63	-0.91	-0.58	0.19	-0.35	0.36	-0.13	0.33
<i>A850.00</i>	0.19	-0.03	0.38	0.86	0.02	0.18	1	-0.18	0.32	0.73	-0.03	-0.11	-0.29	-0.32	-0.21	-0.47	0.01	-0.44	-0.16
<i>Q850.00</i>	0.57	0.62	0.18	-0.45	0.68	0.58	-0.18	1	0.44	0.26	0.5	0.4	-0.49	-0.28	0.2	-0.06	0.18	0.06	0.27
<i>T5000.00</i>	0.82	0.64	0.61	-0.1	0.6	0.81	0.32	0.44	1	0.86	0.52	0.05	-0.97	-0.42	-0.11	-0.33	0.09	-0.1	0.09
<i>A500.00</i>	0.73	0.49	0.64	0.32	0.48	0.75	0.73	0.26	0.86	1	0.41	0.14	-0.87	-0.53	-0.11	-0.51	0.16	-0.33	0.06
<i>Q500.00</i>	0.54	0.5	0.28	-0.36	0.42	0.65	-0.03	0.5	0.52	0.41	1	0.41	-0.59	-0.36	0.19	-0.12	0.31	0.03	0.24
<i>T85/500.00</i>	0.5	0.49	0.23	-0.41	0.34	0.63	-0.11	0.4	0.05	0.14	0.41	1	-0.27	-0.42	0.46	-0.16	0.48	-0.08	0.45
<i>A85/500.00</i>	-0.88	-0.71	-0.63	0.17	-0.65	-0.91	-0.29	-0.49	-0.97	-0.87	-0.59	-0.27	1	0.51	0.01	0.37	-0.21	0.14	-0.2
<i>USUP</i>	-0.49	-0.33	-0.42	-0.03	-0.41	-0.58	-0.32	-0.28	-0.42	-0.53	-0.36	-0.42	0.51	1	-0.1	0.69	-0.44	0.46	-0.32
<i>VSUP</i>	0.06	0.1	-0.03	-0.29	0.12	0.19	-0.21	0.2	-0.11	-0.11	0.19	0.46	0.01	-0.1	1	0.31	0.64	0.22	0.52
<i>U850.00</i>	-0.36	-0.24	-0.33	-0.27	-0.27	-0.35	-0.47	-0.06	-0.33	-0.51	-0.12	-0.16	0.37	0.69	0.31	1	-0.05	0.72	0
<i>V850.00</i>	0.18	0.14	0.13	-0.19	0.15	0.36	0.01	0.18	0.09	0.16	0.31	0.48	-0.21	-0.44	0.64	-0.05	1	-0.03	0.75
<i>U500.00</i>	-0.1	0	-0.19	-0.37	-0.06	-0.13	-0.44	0.06	-0.1	-0.33	0.03	-0.08	0.14	0.46	0.22	0.72	-0.03	1	0.1
<i>V500.00</i>	0.24	0.26	0.09	-0.32	0.27	0.33	-0.16	0.27	0.09	0.06	0.24	0.45	-0.2	-0.32	0.52	0	0.75	0.1	1

Tabla 5.9: Matriz de correlación de las variables observadas, arriba, y de las generadas por CGCM1, abajo, para el periodo 1990-2000.

<i>TMAX</i>	1	0.54	0.67	0.13	0.41	0.66	0.38	0.52	0.52	0.56	0.24	0.26	-0.61	-0.24	0.25	-0.05	0.17	0.02	-0.01
<i>TMIN</i>	0.54	1	-0.26	-0.17	0.62	0.47	0.03	0.63	0.32	0.23	0.33	0.24	-0.4	-0.14	0.14	0.03	0.15	0.13	0.15
<i>TDIF</i>	0.67	-0.26	1	0.29	-0.07	0.34	0.41	0.05	0.31	0.43	-0.01	0.09	-0.35	-0.15	0.16	-0.09	0.06	-0.09	-0.14
<i>PSUP</i>	0.13	-0.17	0.29	1	-0.11	0.16	0.92	-0.11	0.3	0.7	-0.05	-0.13	-0.3	-0.15	-0.18	-0.22	-0.21	-0.32	-0.32
<i>QSUP</i>	0.41	0.62	-0.07	-0.11	1	0.47	0.09	0.64	0.29	0.26	0.3	0.28	-0.38	-0.37	0.31	-0.19	0.36	0.01	0.25
<i>T850.00</i>	0.66	0.47	0.34	0.16	0.47	1	0.44	0.65	0.65	0.73	0.33	0.55	-0.85	-0.33	0.28	-0.2	0.38	-0.05	0.23
<i>A850.00</i>	0.38	0.03	0.41	0.92	0.09	0.44	1	0.13	0.5	0.89	0.08	0.01	-0.54	-0.02	-0.02	-0.27	-0.05	-0.28	-0.22
<i>Q850.00</i>	0.52	0.63	0.05	-0.11	0.64	0.65	0.13	1	0.41	0.38	0.35	0.38	-0.54	-0.38	0.31	-0.13	0.41	0.09	0.31
<i>T500.00</i>	0.56	0.23	0.43	0.7	0.26	0.73	0.89	0.38	0.79	1	0.28	0.05	-0.87	-0.14	0.1	-0.23	0.1	-0.17	-0.09
<i>Q500.00</i>	0.24	0.33	-0.01	-0.05	0.3	0.33	0.08	0.35	0.41	0.28	1	-0.04	-0.42	-0.17	0.16	0.02	0.17	0.11	0.1
<i>T85/50.00</i>	0.26	0.24	0.09	-0.13	0.28	0.55	0.01	0.38	-0.28	0.05	-0.04	1	-0.08	-0.26	0.19	-0.22	0.36	-0.14	0.38
<i>A85/50.00</i>	-0.61	-0.4	-0.35	-0.3	-0.38	-0.85	-0.54	-0.54	-0.9	-0.87	-0.42	-0.08	1	0.23	-0.2	0.13	-0.24	0.01	-0.07
<i>USUP</i>	-0.24	-0.14	-0.15	-0.15	-0.37	-0.33	-0.02	-0.38	-0.15	-0.14	-0.17	-0.26	0.23	1	-0.71	0.31	-0.64	0	-0.45
<i>VSUP</i>	0.25	0.14	0.16	-0.18	0.31	0.28	-0.02	0.31	0.15	0.1	0.16	0.19	-0.2	-0.71	1	-0.13	0.57	0.11	0.42
<i>U850.00</i>	-0.05	0.03	-0.09	-0.22	-0.19	-0.2	-0.27	-0.13	-0.03	-0.23	0.02	-0.22	0.13	0.31	-0.13	1	-0.43	0.59	-0.24
<i>V850.00</i>	0.17	0.15	0.06	-0.21	0.36	0.38	-0.05	0.41	0.12	0.1	0.17	0.36	-0.24	-0.64	0.57	-0.43	1	-0.03	0.66
<i>U500.00</i>	0.02	0.13	-0.09	-0.32	0.01	-0.05	-0.28	0.09	0.07	-0.17	0.11	-0.14	0.01	0	0.11	0.59	-0.03	1	0.1
<i>V500.00</i>	-0.01	0.15	-0.14	-0.32	0.25	0.23	-0.22	0.31	-0.08	-0.09	0.1	0.38	-0.07	-0.45	0.42	-0.24	0.66	0.1	1
<i>TMAX</i>	1	0.59	0.32	-0.15	0.4	0.77	0.07	0.26	0.24	0.3	0.19	0.6	-0.49	-0.21	0.47	0	0.38	-0.03	0.38
<i>TMIN</i>	0.59	1	-0.58	-0.31	0.49	0.46	-0.2	0.4	0.04	-0.04	0.22	0.44	-0.2	0.04	0.36	0.14	0.21	0.1	0.29
<i>TDIF</i>	0.32	-0.58	1	0.21	-0.16	0.24	0.3	-0.21	0.2	0.35	-0.06	0.1	-0.25	-0.26	0.05	-0.16	0.14	-0.15	0.04
<i>PSUP</i>	-0.15	-0.31	0.21	1	-0.14	-0.19	0.94	-0.38	0.23	0.72	-0.28	-0.37	-0.11	-0.19	-0.37	-0.47	-0.21	-0.42	-0.3
<i>QSUP</i>	0.4	0.49	-0.16	-0.14	1	0.35	-0.05	0.52	0.15	0.09	0.14	0.24	-0.25	-0.16	0.32	0.02	0.2	0.01	0.28
<i>T850.00</i>	0.77	0.46	0.24	-0.19	0.35	1	0.09	0.3	0.39	0.44	0.47	0.73	-0.72	-0.4	0.56	-0.04	0.6	-0.08	0.45
<i>A850.00</i>	0.07	-0.2	0.3	0.94	-0.05	0.09	1	-0.31	0.34	0.87	-0.13	-0.16	-0.31	-0.31	-0.21	-0.49	0	-0.44	-0.18
<i>Q850.00</i>	0.26	0.4	-0.21	-0.38	0.52	0.3	-0.31	1	-0.01	-0.17	0.31	0.31	-0.08	-0.06	0.33	0.19	0.2	0.13	0.25
<i>T500.00</i>	0.24	0.04	0.2	0.23	0.15	0.39	0.34	-0.01	1	0.7	0.19	-0.35	-0.88	-0.08	0.04	0.04	0.15	-0.01	0.01
<i>A500.00</i>	0.3	-0.04	0.35	0.72	0.09	0.44	0.87	-0.17	0.7	1	0.08	-0.07	-0.74	-0.36	-0.02	-0.37	0.2	-0.35	-0.01
<i>Q500.00</i>	0.19	0.22	-0.06	-0.28	0.14	0.47	-0.13	0.31	0.19	0.08	1	0.33	-0.34	-0.17	0.31	0.1	0.34	0.09	0.22
<i>T85/50.00</i>	0.6	0.44	0.1	-0.37	0.24	0.73	-0.16	0.31	-0.35	-0.07	0.33	1	-0.08	-0.35	0.54	-0.07	0.5	-0.08	0.44
<i>A85/50.00</i>	-0.49	-0.2	-0.25	-0.11	-0.25	-0.72	-0.31	-0.08	-0.88	-0.74	-0.34	-0.08	1	0.26	-0.25	0.03	-0.38	0.07	-0.23
<i>USUP</i>	-0.21	0.04	-0.26	-0.19	-0.16	-0.4	-0.31	-0.06	-0.08	-0.36	-0.17	-0.35	0.26	1	-0.21	0.62	-0.5	0.48	-0.31
<i>VSUP</i>	0.47	0.36	0.05	-0.37	0.32	0.56	-0.21	0.33	0.04	-0.02	0.31	0.54	-0.25	-0.21	1	0.24	0.64	0.19	0.55
<i>U850.00</i>	0	0.14	-0.16	-0.47	0.02	-0.04	-0.49	0.19	0.04	-0.37	0.1	-0.07	0.03	0.62	0.24	1	-0.08	0.75	0.03
<i>V850.00</i>	0.38	0.21	0.14	-0.21	0.2	0.6	0	0.2	0.15	0.2	0.34	0.5	-0.38	-0.5	0.64	-0.08	1	-0.05	0.76
<i>U500.00</i>	-0.03	0.1	-0.15	-0.42	0.01	-0.08	-0.44	0.13	-0.01	-0.35	0.09	-0.08	0.07	0.48	0.19	0.75	-0.05	1	0.09
<i>V500.00</i>	0.38	0.29	0.04	-0.3	0.28	0.45	-0.18	0.25	0.01	-0.01	0.22	0.44	-0.23	-0.31	0.55	0.03	0.76	0.09	1

Tabla 5.10: Matriz de correlación de las anomalías observadas, arriba, y generadas por CGCM1, abajo, para el periodo 1990-2000.

### Conclusiones acerca del grado de reproducción, por parte de CGCM1, de las variables medidas en Zaragoza

Dado que el modelo produce datos que representan una situación meteorológica media en un área muy amplia, las variables generadas no tienen que corresponder con las características de un observatorio particular. A pesar de ello, en algunas variables las discrepancias se concentran en una época del año o se reducen a la posición central, por lo que las anomalías pueden tener, en algunos periodos, un comportamiento similar al de las anomalías observadas. Resumimos a continuación las conclusiones finales del análisis comparativo realizado:

- Los valores generados de humedad específica en 500hPa tienen, salvo en Primavera, características estadísticas similares a los datos registrados en Zaragoza.
- Las series de  $TMAX$ ,  $T850.00$  y  $A85/50.00$  generadas tienen distinto nivel medio y distinta variabilidad en la mayoría de los meses y sus anomalías tienen una distribución diferente de la observada.
- La distribución de frecuencias de la procedencia del viento simulado, especialmente en superficie, es muy distinta de la observada.
- Como resumen del test global cuya hipótesis nula establece la igualdad de distribuciones, se concluye:
  - No se acepta la hipótesis de igualdad en ninguna variable.
  - Se acepta la hipótesis nula, con distintos niveles de significación, para las anomalías de la humedad en las tres alturas, para las de presión y rango de temperatura en superficie, para las de altura y componentes de viento en el geopotencial 850hPa así como para las de la componente V en 500hPa. El test global relativo a la igualdad de varianzas no rechaza la hipótesis nula en  $z.A850.00$  y  $z.QSUP$ .
  - Aplicando el test anterior por estaciones, se acepta la igualdad de distribución en dos o más estaciones en el caso de las variables  $Q500.00$  y  $U850.00$  y en todas las anomalías salvo  $z.T850.00$ ,  $z.A85/50.00$  y  $z.USUP$ .

El análisis pormenorizado por estaciones nos ha mostrado que existen incidencias a tener en cuenta en el uso de estas variables en el downscaling.

- La estructura de autocorrelación es similar, en general, en ambos conjuntos de datos, tanto en el caso de las variables como de las anomalías. Las discrepancias más relevantes se encuentran en las series de *TDIF*, *Q850.00*, *T85/50.00* y en las componentes U del viento en las tres alturas así como en sus respectivas series de anomalías.
- El grado de correlación entre las variables no muestra sesgos sistemáticos. Cabe citar que *z.A850.00*, *z.Q850.00* y las anomalías de la componente U del viento en los tres niveles tienen coeficientes de correlación de distinto signo en los dos conjuntos de datos.

## 5.7 Modelo *Down1*

Se va a construir un modelo estadístico, del tipo de los ajustados en el capítulo 3, para realizar el downscaling de la lluvia diaria. Los modelos más complejos ajustados en Zaragoza en aquel capítulo, incluían en sus predictores información sobre la presión en superficie, la altura de los niveles geopotenciales, la temperatura, humedad, dirección y velocidad del viento en superficie y en distintos niveles geopotenciales, así como variables indicadoras de la ocurrencia de precipitación en los días previos. Aparecían en ellos también interacciones de las distintas covariables con retardos de la respuesta y con un factor que representaba la partición de la rosa de vientos en superficie.

Un modelo adecuado para el downscaling debe proporcionar el mejor ajuste posible del fenómeno pero, a diferencia del capítulo 3, la información a utilizar debe ser sólo la de aquellas variables cuya distribución esté bien reproducida por CGCM1. El primer paso para la construcción del modelo será la selección de las covariables potenciales; por distintas razones hemos descartado algunas en la construcción de un primer modelo de downscaling, que denotamos *Down1*:

- No vamos a utilizar los indicadores de lluvia en los días previos puesto que los valores de precipitación generados por CGCM1 no corresponden con las observaciones en Zaragoza.
- La distribución de frecuencias de la dirección del viento simulada ha mostrado discrepancias importantes con la observada en las tres alturas, lo que nos ha llevado a prescindir de esa información.
- Respecto a las demás variables, hemos visto en la sección anterior que los valores generados por el GCM, salvo  $Q_{500.00}$  y no a lo largo de todo el año, tienen una distribución distinta a la observada, de modo que hemos decidido formular un modelo basado sólo en anomalías.

Hemos considerado útiles todas aquellas anomalías en las que el test KS produce un p-valor mayor que 0.01 en, al menos, seis de los doce meses. La selección se ha hecho atendiendo a los resultados de este test porque contrasta la igualdad de la distribución frente a los aspectos parciales que analizan otros contrastes. Con este criterio, relativamente laxo, hemos pretendido disponer de una amplia gama de covariables con las que se pudiera obtener un buen ajuste.

De acuerdo con ese criterio, no se utilizarán las anomalías de la temperatura máxima, la temperatura en 850hPa y el espesor de la capa 850-500hPa

y se consideran potencialmente útiles las anomalías de:

- la temperatura mínima, el rango diario de temperatura, la presión atmosférica y la humedad específica, en superficie,
- la altura y la humedad específica, en el geopotencial 850hPa,
- la altura, la humedad y la temperatura, en el geopotencial 500hPa,
- la diferencia de temperatura entre los dos niveles geopotenciales.

El modelo *Down1* se ha construido con el criterio de maximizar el porcentaje de variabilidad explicada de la respuesta. Se ha considerado conveniente incluir en el predictor no sólo los retardos de las covariables sino también sus valores en el día siguiente. Esto viene motivado, por una parte, porque la finalidad del modelo permite esa posibilidad y, segundo, por la necesidad de contar con la mayor información posible de las covariables utilizables, ya que no se van a poder emplear otras que resultaron relevantes en los modelos del capítulo 3. La estrategia utilizada para realizar el ajuste es la habitual; la única diferencia radica en que, tras estudiar el efecto de los retardos de una covariable, se analiza el de su adelanto. El modelo se ha ajustado con los datos observados en el periodo 1990-1997 y se han reservado para la validación los años 1998 a 2000.

Como se ha señalado en la sección 5.5, el modelo estadístico debe, además de ser correcto y ajustar adecuadamente, reproducir el régimen de lluvia observado cuando se utiliza con las covariables generadas por el GCM para la época actual. Por este motivo, el procedimiento de diagnóstico habitual se completa con un análisis de las simulaciones obtenidas usando las covariables observadas, a fin de reconocer las carencias del modelo en la reproducción de las características de lluvia. De ese modo, al analizar las simulaciones que utilicen los valores generados por CGCM1 distinguiremos qué problemas son asignables al modelo y cuáles a una inadecuada reproducción de las covariables por parte de CGCM1.

En los dos primeros apartados de esta sección se presentan y critican los submodelos de ocurrencia, denotado *Down1-Oc*, y de cantidad, *Down1-C*; finalmente, en la subsección 5.7.3 se lleva a cabo la simulación del modelo usando las covariables observadas.

### 5.7.1 Modelo de ocurrencia de *Down1*

El submodelo de ocurrencia de *Down1*, ver tabla C.12, utiliza como covariables los armónicos hasta el orden 4 y las anomalías de:

- En superficie, la temperatura mínima, el rango de temperatura, la presión, las tres con un efecto negativo, y la humedad, que tiene el mayor valor del estadístico  $t$  en el modelo.
- La altura del nivel geopotencial 850hPa, a las 0 y 24 horas, ambas con un efecto positivo.
- La altura y la humedad en el geopotencial 500hPa, esta última a las 0 y a las 24 horas.

El porcentaje de variabilidad explicada globalmente, un 44%, es menor que el obtenido con el modelo *CM sondeos* o el modelo no causal ajustado en Zaragoza, un 49% y un 53.5% respectivamente. Por estaciones, con la excepción del Verano, *Down1–Oc* explica más del 40% de la variabilidad, siendo los porcentajes sólo 4 puntos menores que los correspondientes de *CM sondeos*, ver tabla A.66. En Verano el modelo explica un 35% de la variabilidad, lo que supone una reducción fuerte frente al 48% de *CM sondeos*. El peor comportamiento en el Verano se refleja en %*NAS*, definido con el umbral de la frecuencia relativa, igual a un 37% frente a un 54% en Primavera. Debe destacarse que con ese umbral se clasifican bien un 80% de los días y un 63% de los días iniciales de racha seca.

A diferencia de los modelos ajustados en el capítulo 3, los residuos presentan una autocorrelación de orden 1 estadísticamente significativa al 5%, ver tabla C.13.

El modelo reproduce adecuadamente el ciclo anual, como lo indica el coeficiente de correlación de 0.98 entre la frecuencia mensual de días de lluvia predichos y observados y como se aprecia en la figura 5.16, donde no se distinguen las líneas correspondientes a la frecuencia observada y a la probabilidad de lluvia ajustada.

La tabla C.14 recoge las medidas que permiten valorar el comportamiento del modelo en el periodo de validación, 1998-2000. Globalmente, el porcentaje de días bien clasificados se mantiene en un 83% y el de variabilidad explicada en un 41%. La reducción que se produce en este último índice respecto al periodo de estimación en las dos estaciones húmedas está próxima al 10%.

### Distribución de las longitudes de racha

Se han simulado 20 trayectorias de este modelo, basadas en los datos observados del periodo 1990-2000, con el fin de analizar la reproducción de

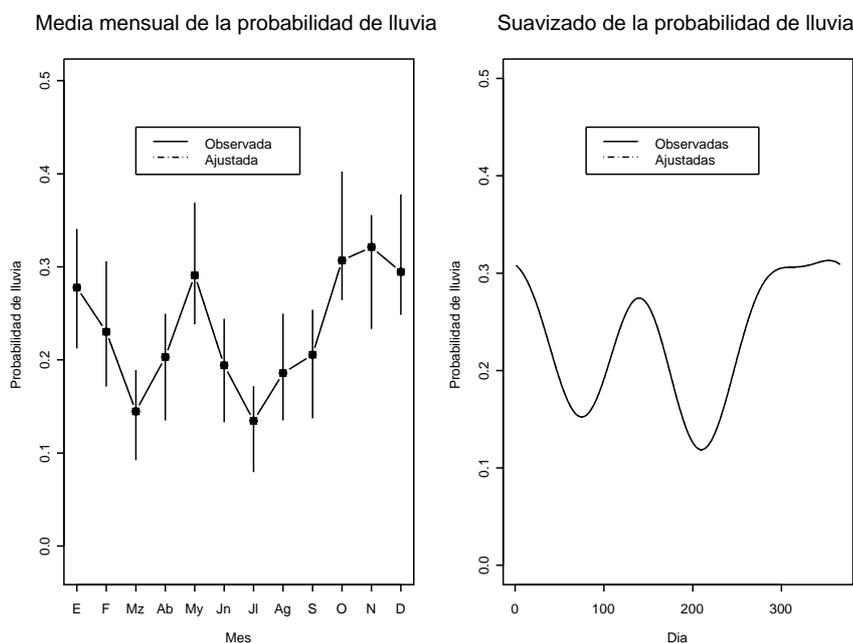


Figura 5.16: Frecuencia relativa de días de precipitación observada y probabilidades ajustadas por el modelo *Down1* (1990-1997). Izda.: Valores medios mensuales. Dcha.: Suavizados de los valores medios diarios.

las características relacionadas con la persistencia. Las simulaciones proporcionan valores medios de las autocorrelaciones de orden 1 y 2 semejantes a los observados, hay discrepancia en el retardo de orden 4 y similitud en los órdenes superiores, ver figura 5.17 izquierda.

Para las rachas secas, los valores de los estadísticos y los p-valores de los contrastes habituales se muestran en la tabla C.15, tanto para el periodo de estimación como para el de validación. En el primero no se encuentran diferencias significativas al 5% en ningún mes, aunque hay discrepancias mayores que el 30% del valor observado en las medianas de Enero y Marzo y en los percentiles 95 de Febrero, Abril, Mayo, Junio y Diciembre. En el periodo de validación se observan, en los valores medianos, discrepancias mayores que las del periodo de estimación, destacando los meses de Febrero, Junio y Diciembre; sin embargo no se rechaza la igualdad de distribuciones entre las rachas observadas y simuladas.

En la tabla C.16 se muestran los resultados correspondientes a las longitudes de racha húmeda. Ni en el periodo de estimación, ni en el de validación, el test KS rechaza al 5% la hipótesis de igualdad de distribuciones en algún

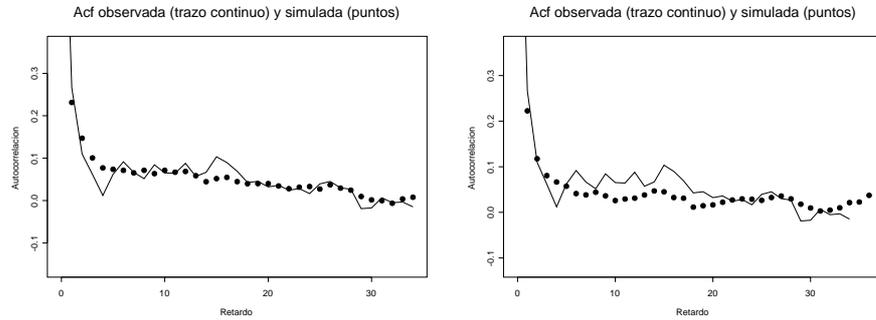


Figura 5.17: Correlogramas correspondientes a la serie de ocurrencia observada y a las series simuladas con el modelo de ocurrencia de *Down1*. Izda.: Usando los datos observados en 1990-2000. Dcha.: Usando datos generados por CGCM1 para 1990-2000.

mes. La mayor discrepancia en el valor mediano, en el periodo 1990-1997, se encuentra en el mes de Abril, mientras que en el periodo de validación se produce en los de Febrero y Abril, siendo ambas significativas al 5% con el test de Wilcoxon.

### 5.7.2 Modelo de cantidad de *Down1*

El submodelo de cantidades de *Down1* es un GLM con error Gamma y enlace logarítmico; su predictor lineal se muestra en la tabla C.17 y contiene términos armónicos hasta el orden 4, así como las anomalías de la altura del nivel geopotencial 850hPa y de cuatro variables de superficie:  $z.PSUP$ ,  $z.QSUP$ ,  $z.TMIN$  y  $z.TDIF$ . Las dos últimas son las covariables con un mayor valor del estadístico  $t$ .

El modelo *Down1-C* explica un 30% de la variabilidad, ver tabla C.18, alcanzando en Primavera un 40% y en Otoño sólo un 18%. Estos porcentajes quedan alejados de los obtenidos con el modelo ajustado en el capítulo 3, donde se alcanzaba, globalmente, un 40%. *Down1-C* reproduce el ciclo estacional de modo aceptable, ver figura 5.18; el coeficiente de correlación entre los respectivos valores medios mensuales es 0.85. Las mayores discrepancias se producen en los meses de Julio y Agosto, donde el modelo sobreestima las cantidades, y en Septiembre donde las subestima.

Si se utiliza la distribución Gamma ajustada para clasificar las cantidades observadas en los intervalos definidos por los dos cuartiles y los dos deciles extremos, la frecuencia en los 5 intervalos definidos resulta próxima a la esperada, aunque sólo un 5% de los datos se clasifican bajo el percentil 10.

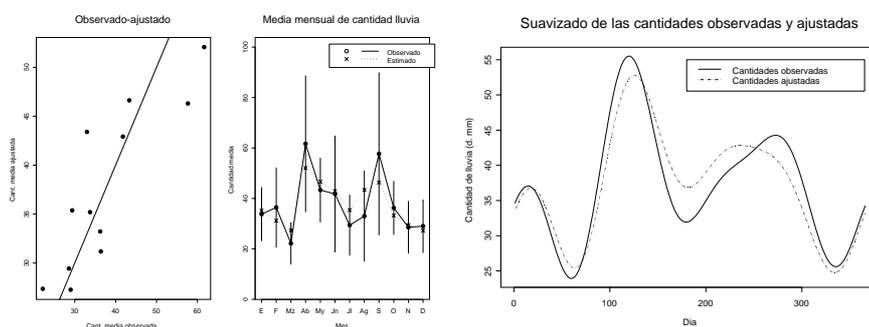


Figura 5.18: Izda.: Medias mensuales de las cantidades diarias observadas y ajustadas por el modelo de cantidad de *Down1* (1990-1997). Dcha.: Suavizado de los valores diarios.

En el conjunto de validación se explica un 34% de la variabilidad, ver tabla C.19, lo que mejora, ligeramente, el valor obtenido en el periodo de estimación. Por estaciones, el porcentaje es más alto en Primavera, un 47% frente al 40% del periodo de estimación, y sólo un 14.4% en Otoño, mientras que es nulo en Verano e Invierno. Como vimos en el capítulo 3, este hecho puede producirse, cuando el tamaño muestral es pequeño, por el mal ajuste de unas pocas observaciones. En este caso se trata de un episodio de precipitación que ocurre entre Enero y Febrero de 1998, en el que se observan grandes discrepancias; prescindiendo de ese episodio el porcentaje de variabilidad explicada llega en Invierno a un 9.8%. En Verano existen dos días, el 1 de Julio de 1998 y el 4 de Junio de 2000, con 4 litros y 2.6 litros observados respectivamente, cuyo valor de  $z.QSUP$  se sitúa entre los máximos observados, lo que produce un fuerte incremento en el predictor lineal; la variabilidad explicada eliminando esos dos datos es un 19.1%.

La reproducción del ciclo anual en el periodo de validación es peor, ver figura 5.19; la cantidad media mensual ajustada supera a la observada en la mayoría de los meses, siendo las diferencias mayores que dos desviaciones típicas en los de Junio, Agosto, Septiembre y Octubre.

### Simulación del modelo de cantidad en los días con lluvia observada

Se han realizado 20 simulaciones del modelo de cantidad utilizando las co-variables observadas en los días húmedos. En la tabla C.20 se comparan algunos percentiles observados con los valores medios obtenidos a partir de las 20 simulaciones. En el periodo de estimación las distribuciones sólo resultan significativamente distintas al 5% en el mes de Mayo, aunque aparecen diferencias mayores que el 30% del valor observado en las medianas de los

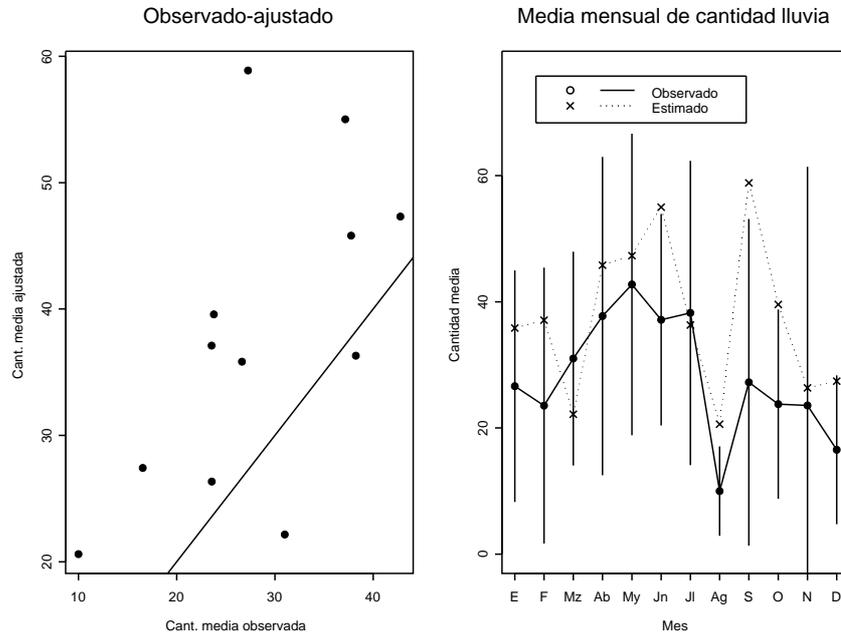


Figura 5.19: Medias mensuales de las cantidades diarias observadas y ajustadas por el modelo de cantidad de *Down1* en el periodo de validación (1998-2000).

meses de Abril, Agosto y Noviembre. El percentil 95 simulado en Abril y Septiembre es la mitad del correspondiente observado y el error supera el 30% en los meses de Febrero, Marzo, Noviembre y Diciembre.

En el periodo de validación no se rechaza la igualdad de distribuciones en ningún mes pero los datos simulados producen valores más discrepantes que en el de estimación; de acuerdo con la sobreestimación vista en la figura 5.19, las medianas simuladas superan en un 50%, e incluso duplican, a las observadas en los meses entre Noviembre y Abril y en el de Agosto.

### 5.7.3 Simulación del modelo *Down1* utilizando los datos observados

El comportamiento global de *Down1* se ha valorado mediante la simulación de 20 trayectorias, utilizando los valores observados de las covariables en el intervalo 1990-2000. En la tabla 5.11 se muestran el número medio de días de lluvia y la media de las cantidades acumuladas, tanto observadas como simuladas, anualmente y por estaciones. La tabla se completa indicando el porcentaje de error que suponen los valores resultantes de las simulaciones respecto a los observados.

Nº medio días lluvia					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Simul.	82.3	22.6	20.2	14.7	25.2
% cambio	0.14	2.7	-10.2	-1.73	10.9
Media cantidad acumulada					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	2920.0	648.0	906.0	518.0	850.0
Simul.	3100.0	722.0	923.0	626.0	826.0
% cambio	6.21	11.3	1.78	20.8	-2.82

Tabla 5.11: Régimen de precipitación observado y obtenido de la simulación del modelo *Down1*, usando los datos observados en el periodo 1990-2000.

La reproducción de estas propiedades agregadas es bastante adecuada. Con respecto a la ocurrencia, se subestima la frecuencia en Primavera y se sobreestima en Otoño, con sesgos que son del orden de un 10%. Para la cantidad de lluvia acumulada, la diferencia más relevante es el incremento de un 20% del valor medio en Verano, que debe achacarse exclusivamente al modelo de cantidad, ya que no aparece ningún sesgo en el de frecuencia, en esa estación.

En las tablas C.21 y C.22 se comparan las distribuciones de las longitudes de racha observada y simulada en cada mes. El test KS no rechaza, al 5%, la igualdad de distribución de las rachas secas en ningún mes; sólo cabe destacar que la mediana simulada es dos días menor en Enero y dos días mayor en Marzo. En las rachas húmedas, el test KS rechaza al 5% la igualdad en el mes de Abril, donde la mediana observada es 2 días y la simulada 1; este hecho y la concentración de los valores simulados en el mes de Mayo en torno a 1 día, explican la disminución de la frecuencia de lluvia en Primavera.

En la tabla C.23 se muestran algunos estadísticos correspondientes a las cantidades observadas y simuladas. Con un nivel de significación del 5% se rechaza la igualdad de distribución en los meses de Noviembre, Diciembre y Marzo, en los que la mediana y el rango intercuartílico simulados son menores que los muestrales, y en los meses entre Abril y Julio, donde se produce el hecho contrario.

Así, el escaso error cometido en el valor medio de la cantidad agregada en Primavera, resulta de una compensación del sesgo que muestran los datos simulados en Marzo, rachas secas más largas y cantidades simuladas menores, con el que produce cantidades mayores que las observadas en los otros dos

meses de esa estación. Asimismo, el sesgo en las cantidades simuladas en Junio y Julio explicaría el error que se produce en la precipitación acumulada en Verano.

En suma, el submodelo de ocurrencia de *Down1* sólo presenta sesgos leves en Primavera y Otoño, que no van acompañados de diferencias significativas en las distribuciones de longitud de racha. Los problemas detectados en las cantidades simuladas en las dos estaciones citadas tienden a compensar estos sesgos pero los provocan en Invierno y, particularmente, en Verano.

	Valores observ.	Valores ajust. (cov. obs.)	Valores ajust. (cov. CGCM1)
Media	0.225	0.224	0.215
Desv. tip.	0.418	0.276	0.243
Q1	0.0	0.018	0.029
Q3	0.0	0.349	0.335

Tabla 5.12: Frecuencia observada y probabilidades de ocurrencia ajustadas con *Down1*, a) usando los datos observados y b) los simulados por CGCM1, periodo 1990-2000.

## 5.8 Simulación de *Down1* con las covariables generadas por CGCM1 para 1990-2000

En esta sección se analizan los resultados que proporciona *Down1* cuando en las simulaciones se utilizan los valores generados por CGCM1 para el periodo 1990-2000. El objetivo es validar *Down1* como modelo para realizar el downscaling de la lluvia e identificar los sesgos ligados a una representación inadecuada de la meteorología de Zaragoza por parte del GCM.

En primer lugar se analizan la ocurrencia de lluvia y las cantidades de precipitación positivas obtenidas mediante este downscaling, comparándolas tanto con las registradas en Zaragoza como con las que proporciona el modelo cuando se usa con los datos observados. Mediante simulación se estudiarán los aspectos relativos a las longitudes de racha y a las cantidades de lluvia. Finalmente se comparará, de forma más agregada, el régimen estacional de precipitación observado y el simulado en estas condiciones.

### 5.8.1 Comportamiento del modelo de ocurrencia

En la tabla 5.12 se muestran algunas medidas descriptivas relativas a la frecuencia de lluvia observada y ajustada en el periodo 1990-2000 y, en la figura 5.20, se muestra esa misma información mensualmente, por lo que se puede apreciar que la calidad del ajuste no es homogénea a lo largo del año. El modelo, cuando usa los datos del GCM, reproduce relativamente bien la forma del ciclo observado, marca dos estaciones húmedas y dos secas, pero se identifican en él algunos sesgos: La lluvia es más frecuente en los meses de Primavera que lo que plantea el downscaling y menos frecuente en el mes de Septiembre; en todos esos meses el valor medio proyectado dista más de dos desviaciones típicas del valor medio observado. En Invierno y en el comienzo de Verano se obtienen valores medios equivalentes.

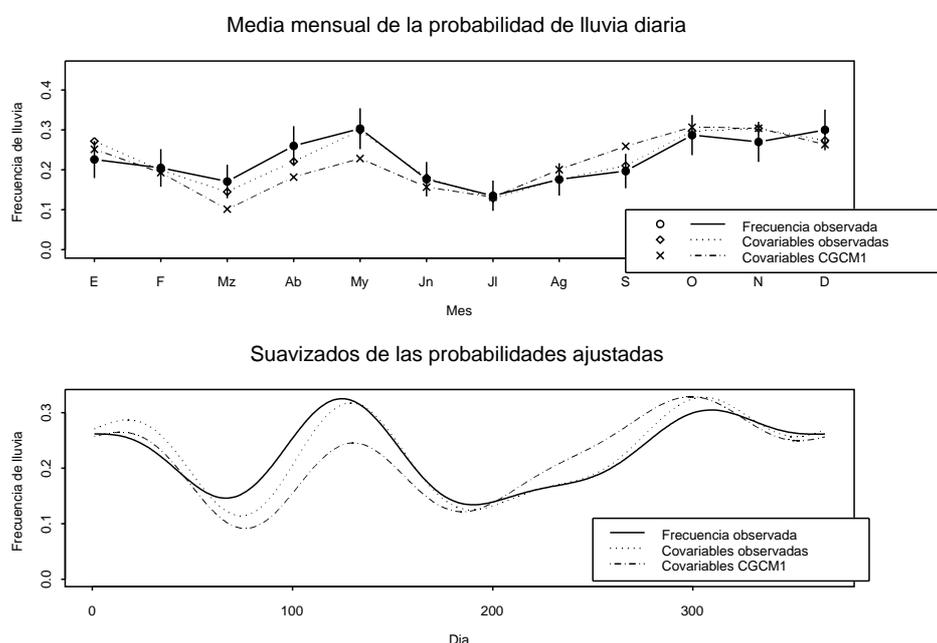


Figura 5.20: Frecuencias y probabilidades de ocurrencia ajustadas con los datos observados en el periodo 1990-2000 y con los datos simulados por CGCM1. Sup.: Valores medios mensuales. Inf.: Valores suavizados.

	Observado	Simulado	
		Cov. observadas	Cov. CGCM1
Media	0.225	0.225	0.215
Desv. tip.	0.418	0.418	0.411

Tabla 5.13: Estadísticos relativos a la ocurrencia observada y simulada por *Down1* usando los datos observados y los generados por CGCM1, periodo 1990-2000.

### Distribución de las longitudes de racha

Se han realizado 20 simulaciones del modelo basadas en los datos generados por CGCM1. En la tabla 5.13 se muestran estadísticos de la frecuencia relativa de lluvia observada y la obtenida en las dos simulaciones.

Al comparar las propiedades de las longitudes de racha seca y húmeda en cada mes con los tests habituales, ver tablas C.21 y C.22, encontramos que la distribución de las rachas secas simuladas no se distingue, de acuerdo con el test KS, de la correspondiente a las rachas observadas en ningún mes. El test de Wilcoxon resulta significativo en Agosto, donde las rachas secas simuladas son más cortas y tienen menor dispersión que las observadas, y en el de Marzo, donde ocurre la situación contraria; estos hechos concuerdan

con el análisis realizado a partir de la figura 5.20.

Los resultados para las rachas húmedas aparecen en la tabla C.22. El test KS es significativo en el mes de Abril, donde se acentúa el mal comportamiento que tenía el modelo cuando lo usábamos con las covariables observadas, y el test de Wilcoxon en los meses entre Febrero y Mayo. La mitad de las rachas húmedas observadas en Abril y Mayo son de 2 ó más días, mientras que en las simulaciones las rachas húmedas de 1 día representan más del 50%, congruente con la subestimación de la respectiva frecuencia mensual que aparece en la figura 5.20.

Cabe concluir que la combinación del modelo y los datos del GCM reproducen adecuadamente, salvo en Primavera, tanto la frecuencia de lluvia observada como las longitudes de racha seca y húmeda. Debe señalarse que las simulaciones, tanto usando los datos observados como los del GCM, presentan un sesgo que tiende a producir rachas más cortas que las observadas, aunque únicamente en algunos meses se obtienen distribuciones significativamente distintas. Las discrepancias en las distribuciones de las rachas secas en Marzo y Agosto y de las húmedas en Febrero, Marzo y Mayo son achacables a la inclusión de covariables mal representadas por CGCM1, que generan un régimen de lluvia distorsionado, que no se producía cuando se simulaba usando las covariables observadas.

### 5.8.2 Cantidad de lluvia en un día húmedo

En la figura 5.21 aparecen los suavizados de las cantidades positivas de lluvia medidas y de las simuladas por el modelo usando los datos de CGCM1. Se concluye que el downscaling provoca sesgos muy importantes al reproducir las cantidades de precipitación; la situación proyectada sitúa los mayores valores medios en Verano, a diferencia del régimen observado que lo hace en Primavera y Otoño. En todos los meses, salvo en Agosto, las simulaciones dan lugar a valores medios menores que los observados; en el caso de los meses de Primavera están separados más de dos desviaciones típicas de la media observada.

En la tabla C.23 se muestran los percentiles de las cantidades positivas observadas y simuladas. El test KS produce p-valores mayores que 0.05 en los meses de Abril, Mayo, Julio y Agosto; en los demás el test KS es significativo y las distribuciones simuladas tienen valores medianos menores y una mayor concentración que la observada. El valor mediano de las cantidades simuladas es algo mayor que el observado en Agosto, al igual que el rango intercuartílico

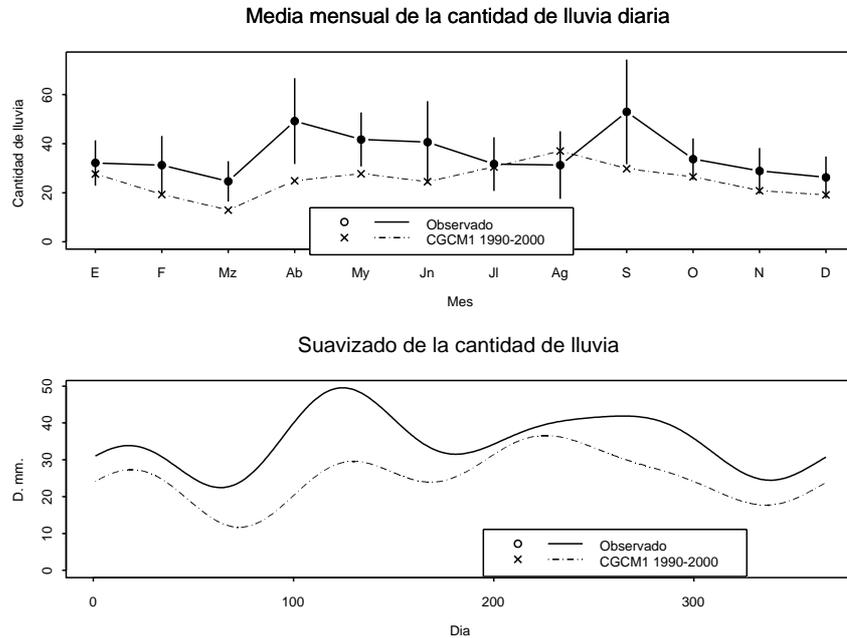


Figura 5.21: Valores medios de las cantidades positivas observadas y simuladas por el modelo *Down1*, usando las covariables generadas por CGCM1 para el periodo 1990-2000. Sup.: Valores medios mensuales. Inf.: Suavizado de los valores diarios.

y el percentil 95.

Al usar los datos del GCM, la separación existente entre los valores medianos observados y simulados, cuando se usaban las covariables observadas, se acentúa en los meses entre Octubre y Marzo y se reduce en los de Abril y Septiembre. Para todos los meses, excepto Agosto, el percentil 95 de la distribución simulada es inferior al de la observada y al obtenido usando las covariables registradas.

Se concluye por tanto que el modelo de cantidad no es adecuado para realizar el downscaling, ya que no es capaz de reproducir el régimen observado de lluvia utilizando los datos del GCM en la situación de control; únicamente en Agosto la reproducción de las cantidades es aceptable. En algunos meses (Marzo, Noviembre, Diciembre) los problemas son achacables, en parte, al propio modelo pero en los de Enero, Febrero y Octubre el rechazo se debe a una mala representación de los datos en el GCM, ya que la simulación a partir de las covariables observadas proporcionaba cantidades no distinguibles de las observadas.

### 5.8.3 Régimen de precipitación

Para valorar globalmente el modelo *Down1*, se presenta la tabla 5.14. En ella se muestran los porcentajes de variabilidad explicada por los submodelos de ocurrencia y cantidad y se calcula la variabilidad explicada por el valor esperado de precipitación diaria, obtenido como producto de la probabilidad de ocurrencia por el valor ajustado de cantidad. En la tabla se incluye el número medio de días con lluvia y la media de la cantidad acumulada anual y estacionalmente, tanto observados como obtenidos en el ajuste. Esos valores medios se calculan a partir de los valores ajustados usando las covariables observadas y las generadas por CGCM1 para el intervalo 1990-2000. El número de días de lluvia esperado anual se calcula como la media de las sumas, en cada año observado, de las probabilidades de ocurrencia ajustadas en cada día; de modo equivalente se calculan las frecuencias esperadas estacionales y la cantidad de lluvia acumulada esperada. El grado de reproducción del régimen de lluvia se mide mediante el porcentaje de error con respecto a los valores observados.

Complementariamente, en la tabla 5.15 se comparan los valores medios, estacionales y anuales, observados y obtenidos en la simulación.

Aunque el modelo propuesto puede considerarse adecuado en lo que se refiere al ajuste que produce cuando se usa con los datos observados, no lo es cuando se utiliza con los datos de CGCM1 para una situación como la actual. En el modelo de ocurrencia se producen insuficiencias en la reproducción del número de días de precipitación en Primavera. Resulta mucho más grave el sesgo en las cantidades acumuladas ya que en todas las estaciones se encuentran errores muy importantes, destacando la pequeña cantidad media que se asocia a Primavera, la estación donde se registra mayor precipitación, que es superada por la lluvia proyectada para Verano.

Los sesgos que produce *Down1* con los datos del GCM representan un inconveniente importante para considerar que las proyecciones generadas en un situación de cambio climático puedan ser verosímiles. Estos problemas nos llevan a estudiar, en el apartado siguiente, las causas de su mal comportamiento y a desarrollar un modelo alternativo que reproduzca el régimen de lluvia actual cuando se realice con él un downscaling de la lluvia usando los datos del GCM para 1990-2000.

% variabilidad explicada por el modelo					
	Global	Invierno	Primav.	Verano	Otoño
Modelo	45.08	52.09	42.33	39.12	39.34
Ocurrencia	43.5	46.38	36.84	46.16	41.22
Cantidad	34.05	43.68	30.46	24.69	26.11
Valores ajustados con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	81.9	21.6	20.6	14.7	24.9
% cambio	-0.317	-1.78	-8.65	-2.11	9.65
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	3090.0	717.0	915.0	642.0	817.0
% cambio	5.91	10.7	0.988	24.0	-3.88
Valores ajustados con datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Proyección 1990-2000	78.6	21.4	15.7	15.0	26.4
% cambio	-4.34	-2.99	-30.3	0.02	16.1
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Proyección 1990-2000	2030.0	482.0	372.0	483.0	692.0
% cambio	-30.4	-25.7	-58.9	-6.64	-18.6

Tabla 5.14: Régimen de precipitación observado y proyectado por *Down1* a partir de los datos observados y generados por CGCM1 para 1990-2000.

Nº medio de días con lluvia					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Simul.	78.5	21.4	15.6	14.8	26.7
% cambio	-4.42	-2.62	-30.8	-1.47	17.5
Media de la cantidad acumulada					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	2920.0	648.0	906.0	518.0	850.0
Simul.	1990.0	477.0	369.0	463.0	682.0
% cambio	-31.8	-26.4	-59.3	-10.7	-19.8

Tabla 5.15: Régimen de precipitación observado y obtenido mediante simulación con *Down1*, usando los datos generados por el GCM para el periodo 1990-2000.

## 5.9 Downscaling con un modelo de lluvia alternativo

Hemos visto que el modelo *Down1* no es útil para realizar el downscaling de la precipitación en un escenario de cambio climático. El objetivo de esta sección es precisar las causas de ese mal comportamiento y construir, a partir de él, un modelo alternativo válido para realizar dicha proyección.

En la subsección 5.9.1 se analiza el comportamiento de distintos modelos en los que se prescinde de covariables significativas de *Down1*. Se concluye que  $z.TMIN$ ,  $z.TDIF$  y  $z.QSUP$  son covariables que, utilizadas en su versión CGCM1, producen sesgos importantes en algunas estaciones del año, a la vez que son necesarias para obtener un buen ajuste. Este problema nos lleva a ensayar modelos en los que esas covariables se utilicen, únicamente, en aquellas estaciones en las que no hay discrepancia entre sus distribuciones observada y simulada. De este modo se selecciona un modelo *Down2*, que ajusta peor pero que reduce los sesgos de *Down1* en la reproducción del régimen de lluvia.

En la segunda subsección se presenta y analiza el modelo alternativo *Down2* y, finalmente, en 5.9.3 se lleva a cabo el downscaling con este modelo y los datos de CGCM1 para el periodo 1990-2000.

### 5.9.1 Identificación de las causas que provocan los problemas de *Down1* en el downscaling

En primer lugar se han ajustado los modelos que resultan al retirar del predictor lineal de *Down1* cada una de sus covariables. Los distintos modelos se han valorado mediante tablas similares a la 5.14, que permiten analizar tanto el grado de ajuste alcanzado como la reproducción del régimen de lluvia y, en consecuencia, su utilidad para el downscaling.

Las tablas C.24 y C.25 contienen los resultados que se obtienen cuando se prescinde de cada una de las tres covariables significativas que muestran peor correspondencia entre sus valores observados y los generados por CGCM1,  $z.TMIN$ ,  $z.TDIF$  y  $z.A500.00$ , ver tabla 5.4, así como los resultados del modelo que prescinde simultáneamente de las dos primeras. El porcentaje de variabilidad explicada por el modelo de cantidades cuando no se utiliza la información de la temperatura mínima y del rango de temperatura, las dos covariables con mayor estadístico  $t$  en *Down1*- $C$ , pasa de un 34% a un 7%. Su ausencia del modelo de ocurrencia provoca una disminución que es sólo

de un 4%. Por otro lado, el modelo sin estas dos covariables, usado con los datos del GCM, disminuye el sesgo que tenía *Down1–Oc* en Primavera, de un 30% a un 18%, pero lo incrementa en Otoño. En cuanto a la cantidad acumulada, se reducen los errores de *Down1* en Invierno y Primavera, que pasan de 26% y 59% a 4% y 9%, respectivamente, mientras que se incrementa el sesgo en Verano, de un 6 a un 25%, y en Otoño, de un 19% a un 31%.

El segundo paso de este análisis ha consistido en la construcción de los modelos de lluvia que explican el mayor porcentaje de variabilidad, cuando se prescinde de algunas covariables de *Down1*: las tres anomalías citadas en el párrafo anterior y *z.QSUP*, variables que en el test KS producen p-valores menores que 0.05 en 2 ó más meses en alguna estación. Un resumen del comportamiento de los modelos más interesantes se muestra en las tablas C.26-C.29.

A partir de esos ensayos llegamos a las siguientes conclusiones:

- La variabilidad explicada por el modelo de cantidad se reduce drásticamente si no se utiliza *z.TDIF*, ver tablas C.26-C.28; sin embargo, la variabilidad explicada por el modelo de ocurrencia supera el 33%.
- Los modelos que no incluyen a *z.QSUP*, ver tablas C.28 y C.29, producen, cuando se usan con los datos de CGCM1, sesgos muy importantes tanto en la frecuencia como en la cantidad acumulada en Verano y Otoño pero no muestran el sesgo de *Down1* respecto a la frecuencia en Primavera.

Ante estos hechos hemos decidido construir un modelo que emplee estas cuatro covariables sólo en aquellas estaciones en las que no se han detectado dificultades con el test KS. Sus anomalías se han considerado utilizables en una estación si existen dos meses, al menos, en los que el test KS produce p-valores superiores a 0.05, ver tabla 5.4. En el caso del rango de temperatura en superficie, en los tres meses de Otoño se obtienen p-valores superiores a 0.01 y, sólo en uno de ellos, un p-valor superior a 0.05; pese a ello hemos decidido utilizarla en el modelo, ver tabla 5.16.

En la tabla C.30 se muestran los resultados de un modelo que no utiliza ninguna de las cuatro covariables; el ajuste muestra sesgos menos importantes que los identificados en *Down1*, el error máximo es de un 15% y se produce en la cantidad media acumulada de Invierno; sin embargo, el modelo es insuficiente ya que los porcentajes de variabilidad explicada por los submodelos de ocurrencia y cantidad son un 29% y un 9.8%, respectivamente.

Anomalía	Invierno	Primavera	Verano	Otoño
$z.TMIN$	Sí	Sí	No	No
$z.TDIF$	Sí	No	Sí	– (sí)
$z.QSUP$	Sí	No	Sí	Sí
$z.A500.00$	No	Sí	Sí	No

Tabla 5.16: Clasificación de las covariables problemáticas de *Down1*, atendiendo a su uso en la construcción del modelo *Down2*; el símbolo – indica una situación dudosa.

Finalmente, hemos ajustado el modelo que denominaremos *Down2* que usa las covariables potenciales seleccionadas para *Down1*, con las restricciones que se han señalado. En la tabla 5.17 se muestran algunas propiedades del nuevo modelo: el submodelo de ocurrencia explica un 38% de la variabilidad, un valor casi tan satisfactorio como el de *Down1–Oc*, y el de cantidad sólo un 14.6%. El downscaling de la precipitación con *Down2* produce errores mucho menores que los de *Down1*, el error máximo es de un 8%.

% variabilidad explicada por el modelo					
	Global	Invierno	Primav.	Verano	Otoño
Modelo	25.52	17.2	32.93	26.26	33.41
Ocurrencia	37.93	32.08	38.35	39.34	40.76
Cantidad	14.6	12.69	19.46	11.17	15.23
Valores ajustados por el modelo, con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	82.4	22.3	20.8	14.7	24.5
% cambio	0.362	1.12	-7.4	-1.76	7.8
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	2950.0	760.0	900.0	507.0	786.0
% cambio	1.19	17.2	-0.658	-2.1	-7.61
Valores ajustados por el modelo, con los datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Proyección 1990-2000	80.8	21.2	20.7	14.6	24.2
% cambio	-1.63	-3.63	-8.03	-2.26	6.22
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Proyección 1990-2000	2740.0	608.0	856.0	485.0	791.0
% cambio	-6.16	-6.23	-5.57	-6.31	-7.03

Tabla 5.17: Régimen de precipitación observado y proyectado por *Down2* a partir de los datos observados y de los generados por CGCM1 para 1990-2000.

### 5.9.2 Modelo *Down2*

En esta subsección se presenta, de modo análogo al de la sección 5.7 con *Down1*, la composición y crítica del modelo *Down2* y se analiza su comportamiento cuando se simula, utilizando las covariables observadas.

#### Modelo de ocurrencia

La composición del predictor lineal del submodelo de ocurrencia se muestra en la tabla C.31. Aparecen en él, además de las covariables habituales, términos de interacción de las variables indicadoras de la estación a la que corresponde el día ajustado, denominadas *invierno*, *primavera*, *verano* y *otoño*, con las anomalías que CGCM1 representa adecuadamente en ese periodo.

El predictor lineal contiene 29 términos, de los que 8 corresponden a armónicos y 9 a efectos comunes a las cuatro estaciones, que están asociados a las anomalías de la presión en superficie, la altura y humedad en el geopotencial 850hPa y la temperatura y humedad en el geopotencial 500hPa. Las anomalías que influyen sólo en determinadas estaciones son: la de temperatura mínima, con efectos de signo contrario en Invierno y Primavera, la del rango de temperatura, que actúa en Invierno y Verano, la de la humedad en superficie, con un coeficiente en Invierno que duplica los de Verano y Otoño, y la de la altura del nivel geopotencial 500hPa, que tiene un efecto más importante en Verano que en Primavera.

Atendiendo al valor absoluto del estadístico  $t$ , la mayor influencia en el modelo corresponde a la presión en superficie y a la temperatura en 500hPa, seguidas de los efectos estacionales del rango de temperatura y de la humedad en superficie, lo que resulta lógico dada su relevancia en el modelo *Down1*. En éste, el predictor lineal del submodelo de ocurrencia incluía 21 términos, de los que 12 están en *Down2*. Recordemos que los efectos más influyentes en *Down1–Oc* correspondían a las cuatro covariables que tienen diferente efecto estacional en *Down2*.

El grado de ajuste de *Down2–Oc* en el periodo de estimación es aceptable: un 39% de variabilidad explicada y un 78.6% de días bien clasificados, cuando se usa como umbral la frecuencia relativa de lluvia, ver tabla C.32 y figura 5.22. Estos porcentajes son algo inferiores a los obtenidos con *Down1*, un 44% y un 79.9% respectivamente. La pérdida de calidad en el grado de ajuste no es homogénea a lo largo del año: en Primavera, el porcentaje de variabilidad explicada pasa de un 48.9% a un 36.1% y en Otoño, de un 47.2%

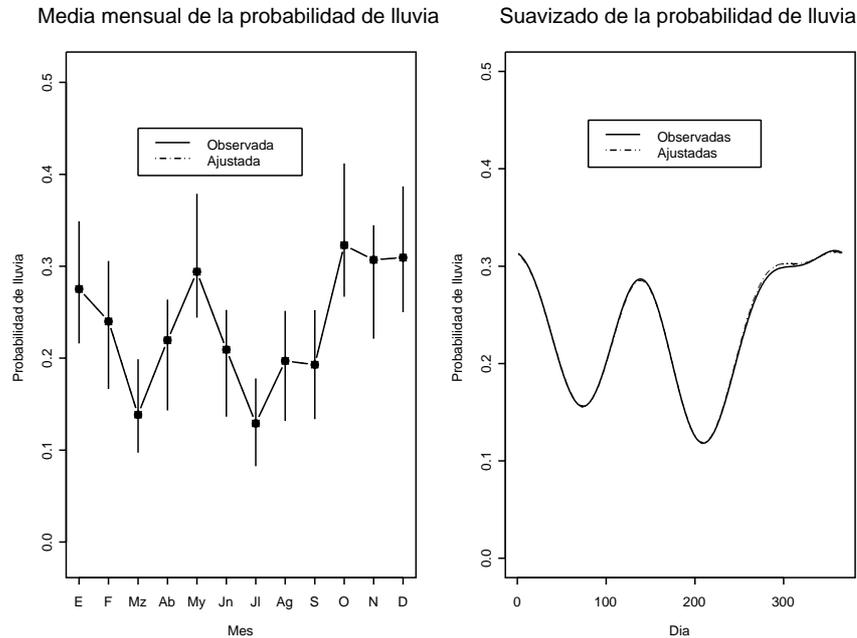


Figura 5.22: Frecuencia relativa de días de precipitación observada y probabilidades ajustadas por el modelo *Down2* con los datos observados en el periodo 1990-1997. Izda.: Valores medios mensuales. Dcha.: Suavizados de los valores diarios.

en *Down1* a un 40.7%, mientras que hay una leve mejora en Verano.

El comportamiento de *Down2–Oc* en el conjunto de validación se resume en la tabla C.33; se obtiene prácticamente el mismo porcentaje de días bien clasificados que en el conjunto de estimación pero hay una reducción importante de la variabilidad explicada en Primavera, de un 13%, y en Otoño, de un 10%. Ese porcentaje de variabilidad explicada en el conjunto de validación es, globalmente, un 32.6%, ver tabla C.14, inferior al obtenido con *Down1–Oc*, un 41.3%.

Se han realizado 20 simulaciones de *Down2–Oc* para analizar la reproducción de las longitudes de racha. La comparación con la distribución observada, ver tablas C.34 y C.35, permite concluir que el modelo de ocurrencia es adecuado, ya que el test KS sólo es significativo al 5% en las rachas húmedas del mes de Febrero, en el periodo de validación. En el periodo de estimación encontramos discrepancias mayores que el 30% del valor mediano observado, que ya aparecieron con *Down1*, en las rachas secas de los meses de Enero, Abril y Noviembre y en las húmedas de Abril y Agosto.

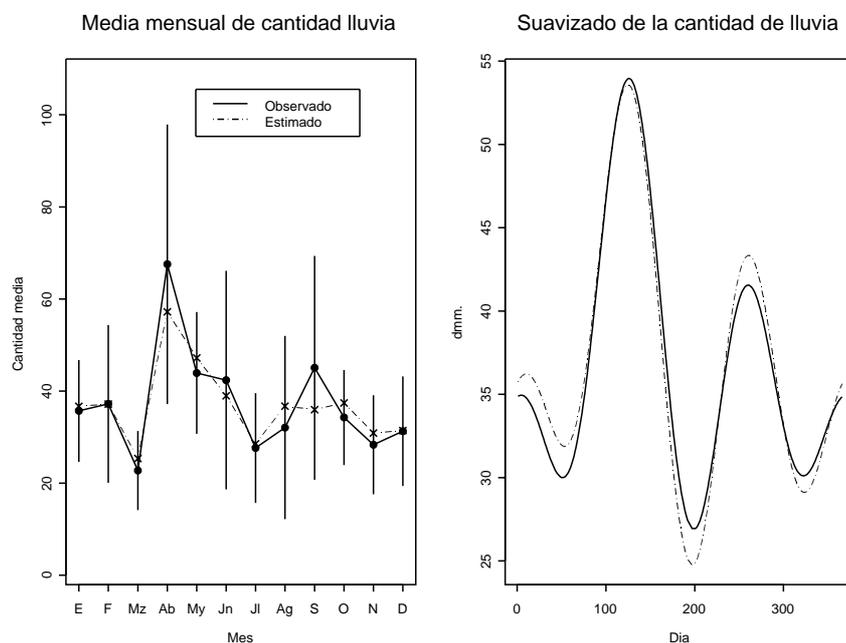


Figura 5.23: Izda.: Medias mensuales de las cantidades diarias observadas y ajustadas por el modelo de cantidad de *Down2* (1990-1997). Dcha.: Suavizado de los valores diarios.

### Modelo de cantidad

El modelo de cantidad incluye en su predictor, ver tabla C.36, armónicos hasta el orden 4 y efectos que actúan durante todo el año, asociados a anomalías de variables de la troposfera: la altura del nivel 850hPa, la humedad en 500hPa y la diferencia de temperaturas entre ambos geopotenciales. Cabe destacar que el predictor no contiene información sobre la presión atmosférica. Los efectos asociados a estaciones particulares son cuatro: la altura del geopotencial 500hPa en Primavera y Verano, el rango de temperatura en Invierno y la humedad en superficie en Verano, no habiendo ningún término propio de Otoño.

Con 18 parámetros, el grado de ajuste es peor que el obtenido con *Down1-C*, que tenía 14 términos, lo que se refleja tanto en un ligero incremento del parámetro de dispersión como en la reducción del porcentaje de variabilidad explicada, sólo un 17.4%, ver tabla C.37. En este porcentaje, la mayor pérdida se produce en Primavera, un 13.6% en *Down2-C* frente a un 40.3% en *Down1-C*, que se puede achacar a haber excluido, en esta estación, la información del rango de temperatura y de la humedad en superficie. No obstante hay aspectos del modelo que no empeoran: el ciclo estacional se

representa adecuadamente, ver figura 5.23, con un coeficiente de correlación 0.93 entre los valores medios mensuales observados y ajustados, cuando en *Down1-C* ese valor era 0.85. Por otra parte la clasificación de las observaciones dentro de los intervalos definidos por los percentiles de la distribución ajustada señala un 5.7% de cantidades menores que el percentil  $q_{0.10}$ , porcentaje similar al 4.9% de *Down1* en el periodo de estimación.

El comportamiento de *Down2* en el conjunto de validación es deficiente, ver tabla C.38; se obtiene un ajuste pobre en algunas estaciones aunque, como ocurría con *Down1*, este hecho está muy influido por unos pocos datos. En Verano se alcanza un 9.9% de variabilidad si se prescinde de cuatro días, el 1/7/1998, 1 y 9 de Junio de 2000, que aparecían como problemáticos en *Down1*, y, además, el 5 de Junio de 1998. En Invierno, si no se incluye el episodio entre finales de Enero y principios de Febrero de 1998, citado también cuando analizamos *Down1*, se alcanza un 18.4% de variabilidad explicada.

Se han realizado 20 simulaciones del modelo en los días en los que se ha observado lluvia, utilizando las covariables correspondientes. En la tabla C.39 se muestran, para cada mes, los percentiles 50 y 95 y el rango intercuartílico de los datos observados y simulados, junto con los p-valores de los tests habituales. Con el test KS no se rechaza en ningún mes la igualdad de distribuciones al 5%. En el periodo de estimación, al igual que con *Down1*, se producen discrepancias mayores que el 30% en el valor mediano observado en los meses de Agosto y Noviembre y, en el de validación, en la mediana de los meses de Invierno, Verano y en Abril y Noviembre, también como con *Down1*.

### **Simulación del modelo *Down2* con los datos observados en el periodo 1990-2000**

Se han simulado 20 series del proceso de ocurrencia y, sobre ellas, usando el modelo de cantidad, 20 series simuladas de lluvia diaria, utilizando los datos observados en el periodo 1990-2000. La reproducción del perfil de ocurrencia, como se aprecia en la figura 5.24, es adecuado.

El valor medio de las cantidades positivas simuladas en todos los meses se diferencia menos de 2 desviaciones típicas de las medias observadas, ver figura 5.25. El test KS para comparar las distribuciones es significativo, al 1%, en los meses de Primavera y en los de Enero y Diciembre y al 5%, además, en los de Septiembre a Noviembre, ver tabla C.42. En los meses de Abril y Mayo la distribución de las cantidades simuladas tiene mayor dispersión,

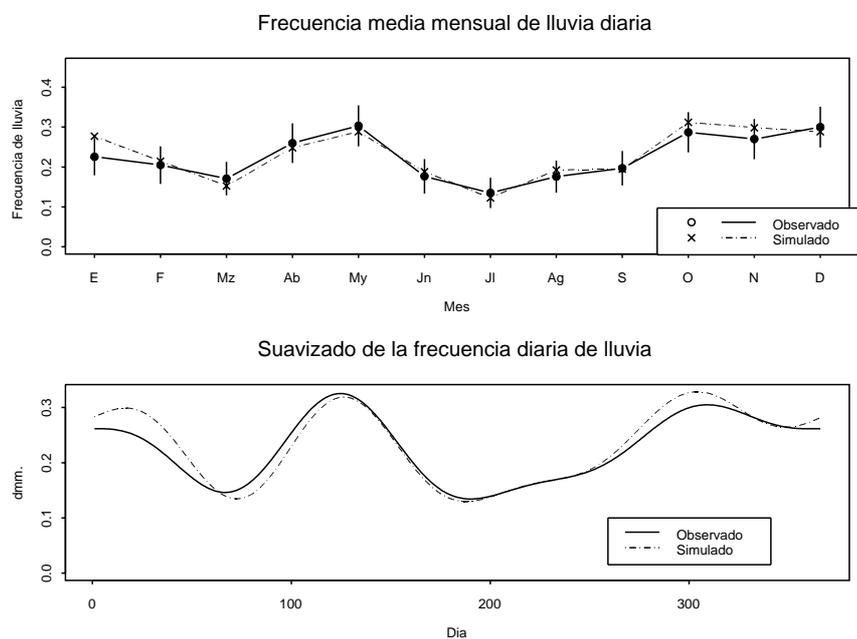


Figura 5.24: Frecuencia media de lluvia observada y simulada con *Down2* utilizando los datos observados en el periodo 1990-2000. Sup.: Valores medios mensuales. Inf.: Valores suavizados.

mientras en Enero y Marzo se da la situación contraria.

Se concluye que el modelo *Down2* representa adecuadamente buena parte de las propiedades de la precipitación observada en Zaragoza. Genera series de ocurrencia indistinguibles de la observada, reproduciendo tanto los valores medios mensuales de frecuencia de lluvia como la distribución de las longitudes de racha húmeda y seca. En cuanto a las cantidades, reproduce los valores medios en todos los meses del año; la distribución no se distingue al 5% de la observada en los meses de Verano y al 1% en los de Otoño; en las otras dos estaciones hay discrepancia.

### 5.9.3 Downscaling con los datos generados por CGCM1 para el periodo 1990-2000

Se han simulado 20 series de lluvia con el modelo *Down2* utilizando los datos generados por CGCM1 para el periodo 1990-2000. El régimen de precipitación obtenido es muy semejante al observado, como puede verse en la tabla 5.24. En ella se aprecia, principalmente, una disminución de los valores medios de la frecuencia y de la cantidad de lluvia en Primavera. Cabe señalar

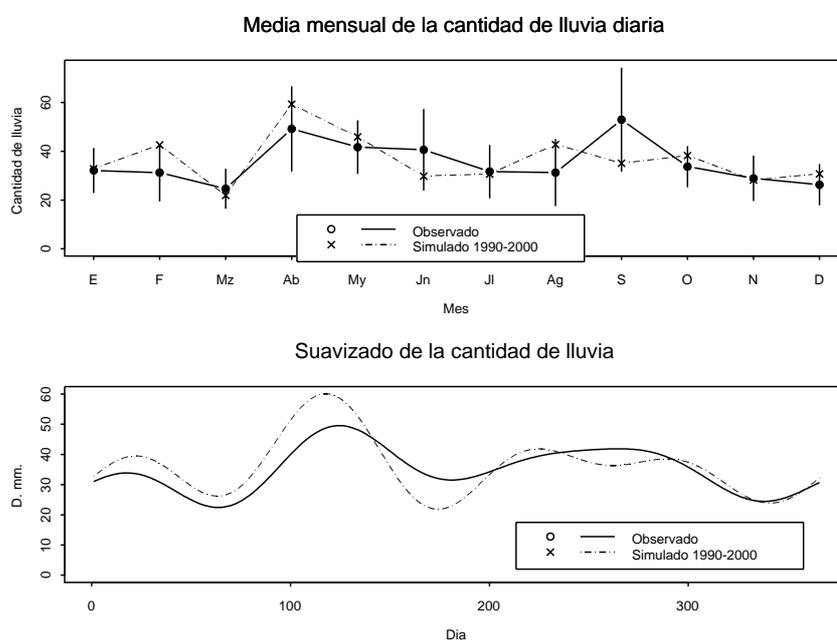


Figura 5.25: Valores medios de las cantidades positivas observadas y simuladas por el modelo *Down2* utilizando los datos observados en el periodo 1990-2000. Sup.: Valores medios mensuales. Inf.: Valores suavizados.

que las desviaciones de los suavizados de las probabilidades ajustadas, con los dos conjuntos de datos, respecto del suavizado de la frecuencia observada, son mínimas, ver figura 5.26.

En relación con la persistencia de días secos y húmedos cabe decir que, para las rachas secas, el test KS sólo rechaza al 5% la hipótesis de igualdad en el mes de Junio, donde se simulan rachas más largas, ver tabla C.40. La reproducción de la distribución observada en las rachas húmedas es de la misma calidad; en la tabla C.41 puede comprobarse que la simulación genera distribuciones que el test KS no distingue de las observadas y que las variaciones en medianas y rangos intercuartílicos, respecto a los valores observados, son poco importantes.

En cuanto a los valores medios de las cantidades simuladas, la figura 5.27 permite establecer que están próximos a los observados en todos los meses del año y que la mayor discrepancia se produce en Septiembre. En cuanto a la distribución por meses, el test KS rechaza al 5% la hipótesis de igualdad en 10 de ellos y al 1% en seis, ver tabla C.42. En los tres primeros meses del año se simulan cantidades con una distribución más concentrada que la observada y

Nº medio días lluvia					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Simul.	81.3	21.6	20.8	14.6	24.2
% cambio	-1.06	-1.85	-7.54	-2.35	6.49
Media cantidad acumulada					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	2920.0	648.0	906.0	518.0	850.0
Simul.	2740.0	621.0	806.0	487.0	820.0
% cambio	-6.31	-4.19	-11.1	-5.88	-3.54

Tabla 5.18: Régimen de precipitación observado y obtenido en la simulación del modelo *Down2* utilizando los datos generados por CGCM1 para el periodo 1990-2000.

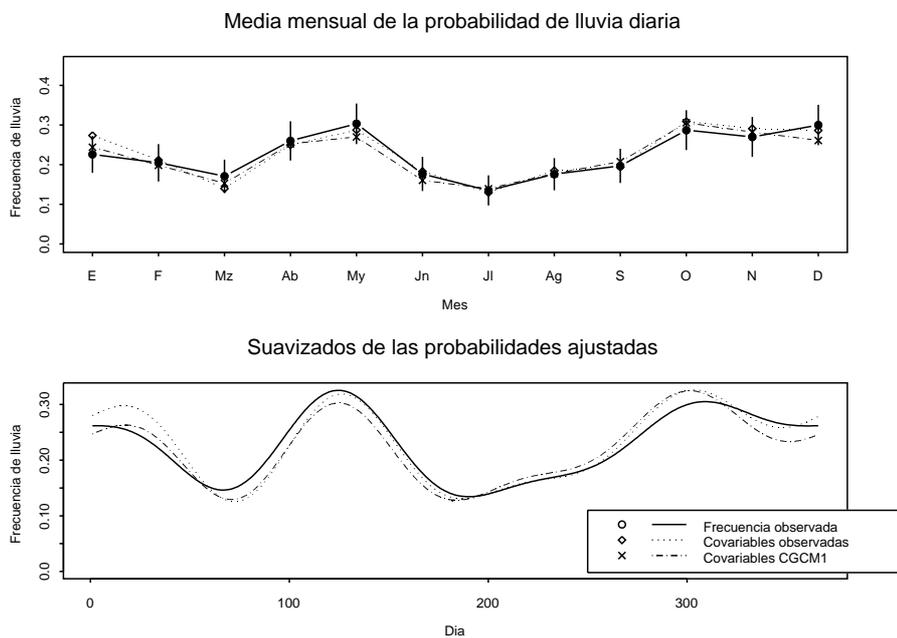


Figura 5.26: Frecuencia media de lluvia observada y probabilidades de ocurrencia ajustadas por *Down2* utilizando los datos observados y los generados por CGCM1 para 1990-2000. Sup.: Valores medios mensuales. Inf.: Suavizados de los valores medios diarios.

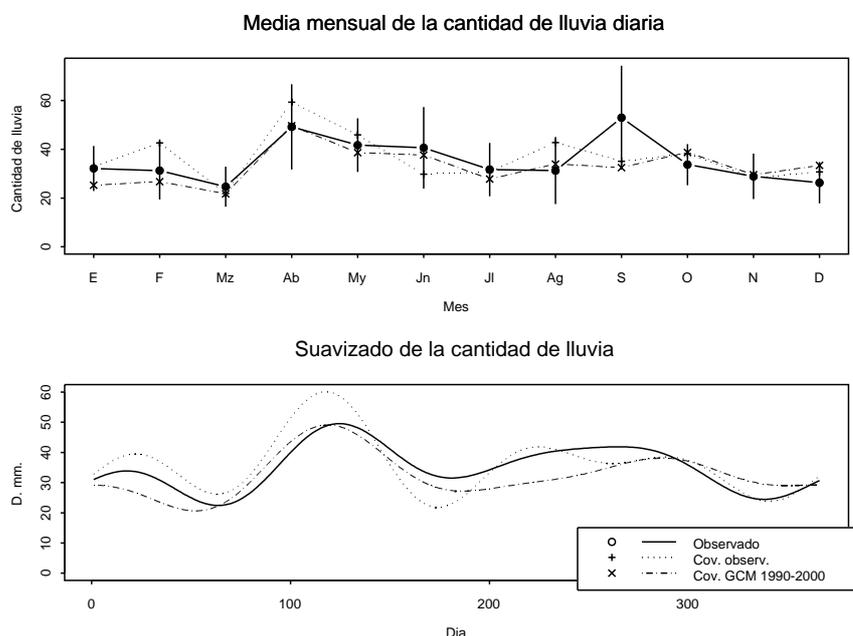


Figura 5.27: Valores medios de las cantidades observadas y simuladas por *Down2* utilizando los datos observados y los generados por CGCM1 para 1990-2000. Sup.: Valores medios mensuales. Inf.: Suavizado de los valores diarios.

localizada en valores menores, mientras que en Abril se produce la situación contraria. En la simulación de las series de cantidades intervienen los dos submodelos aunque, dada la ausencia de problemas en el de ocurrencia, éstos deben achacarse a *Down2-C*.

Al comparar estos resultados con los de *Down1*, cabe señalar que:

- El modelo *Down2* simula rachas secas cuya longitud mediana está más próxima de la observada en los meses de Marzo a Mayo, Agosto y Septiembre, ver tabla C.21. La distribución de las rachas húmedas generadas no se distingue de la observada en ningún mes, lo que resuelve el problema que presentaba *Down1* con este tipo de rachas en el mes de Abril.

El valor del rango intercuartílico de las rachas húmedas en los meses de Febrero a Julio, así como el de la mediana en los de Abril, Mayo y Octubre, están más próximos de los valores observados en las simulaciones con *Down2*.

- Las cantidades positivas simuladas por *Down2* producen p-valores menores que 0.01 en el test KS en 6 meses. A pesar de ello, los valores si-

mulados de la mediana y el rango intercuartílico están más próximos de los correspondientes valores observados que los simulados por *Down1* en la mayoría de los meses.

Como conclusión, el modelo *Down2* utilizado con los datos procedentes de CGCM1 en las condiciones de clima actual, produce simulaciones con las siguientes propiedades:

- las trayectorias de la serie diaria de ocurrencia tienen las características estadísticas de la serie observada en Zaragoza,
- el modelo proyecta valores medios de cantidades que se corresponden con los observados,
- la distribución de las cantidades positivas simuladas se puede considerar relativamente próxima a la observada en los meses de Mayo a Octubre, salvo en el de Julio, y en el de Diciembre.

Puesto que el downscaling de la lluvia con *Down2* en el clima presente es satisfactorio, consideramos que es un modelo adecuado para aplicarlo en las condiciones de cambio climático.

## 5.10 Proyección de la precipitación diaria en Zaragoza en el periodo 2090-2100

En esta sección se realiza el downscaling de la precipitación para el periodo 2090-2100, en el escenario IS92a. Se obtiene una proyección de la lluvia diaria en el observatorio de Zaragoza a partir de los datos de las covariables generadas en el experimento GHG+A de CGCM1, utilizando el modelo *Down2*.

En primer lugar se analizan los cambios proyectados en dichas covariables respecto de los valores que el GCM genera para el periodo 1990-2000. En la subsección 5.10.2 se presenta el downscaling de la precipitación con el modelo *Down2* y en la 5.10.3 se comparan esas proyecciones con las obtenidas con *Down1* y con las de un modelo que no utiliza información de humedad; esto permite establecer conclusiones sobre la sensibilidad del método de downscaling estadístico al uso de covariables mal representadas y a la no utilización de variables influyentes.

### 5.10.1 Análisis comparativo de los resultados de CGCM1 para los periodos 1990-2000 y 2090-2100

Los datos proporcionados por CGCM1 para el periodo 2090-2100 corresponden a un escenario de calentamiento global en el que se proyectan cambios respecto del régimen actual, no sólo en el comportamiento de la temperatura. Vamos primero a valorar cómo son las modificaciones propuestas, que posteriormente trasladaremos, mediante downscaling, a la precipitación.

En la tabla 5.19 se muestra el valor medio, la desviación típica y los cuartiles  $Q_1$  y  $Q_3$  de las variables simuladas por el GCM, a excepción de las componentes de viento, en los dos periodos. A partir de esa comparación podemos hacer una descripción somera de cuáles son los cambios climáticos proyectados.

- Las características de posición central y cuartiles de las temperaturas a finales del s. XXI serían superiores a las actuales. El calentamiento se traduce en un incremento de unos 4°C en el valor medio de las temperaturas máxima y mínima en superficie e incrementos mayores a más altura: 4.5°C para la temperatura en el geopotencial 850hPa y 6°C en el nivel 500hPa. En la figura 5.28 se muestran los diagramas de caja por meses y los valores medios suavizados de *TMIN*, variable en la que los cambios son algo mayores para los meses más cálidos y más

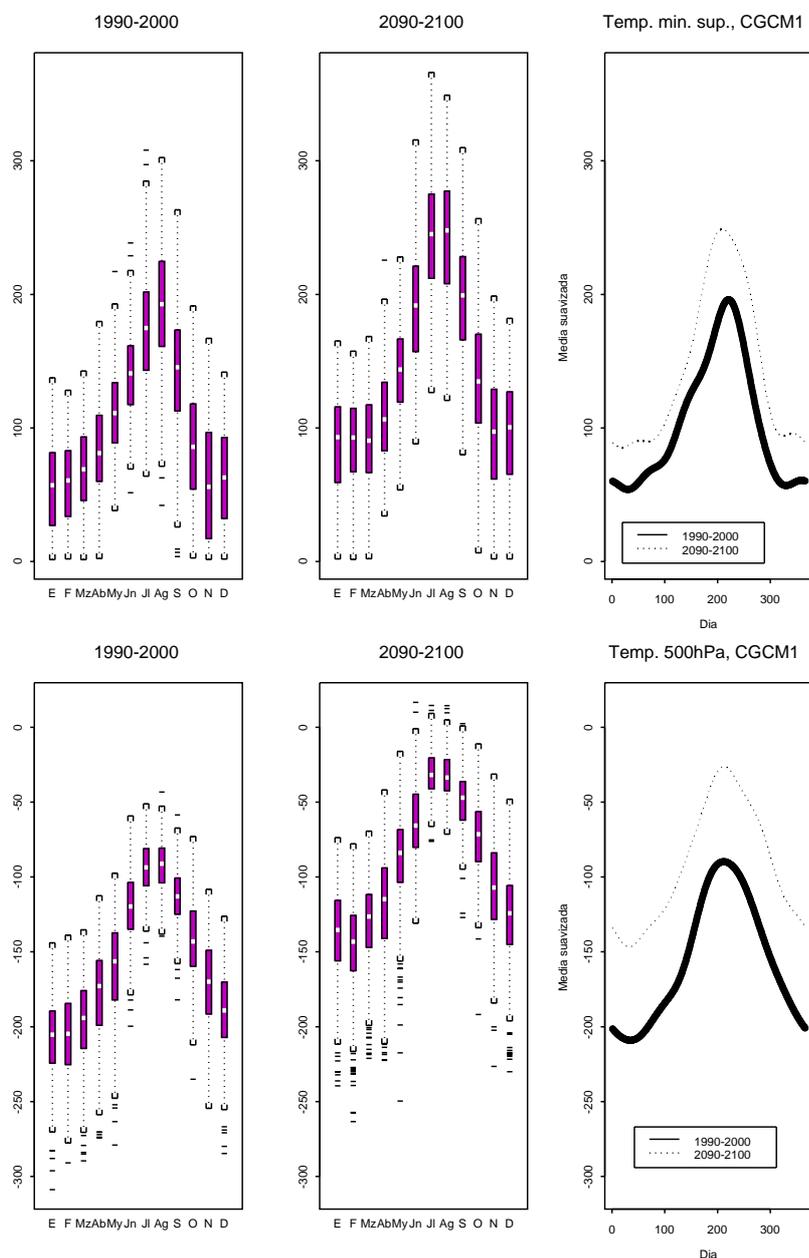


Figura 5.28: Diagramas de caja por meses y suavizado de los datos de temperatura mínima en superficie y de temperatura en la altura geopotencial 500hPa, generados por CGCM1 para los periodos 1990-2000 y 2090-2100.

Variable	$\bar{x}$		$\hat{s}$		$Q_1$		$Q_3$	
	1990	2090	1990	2090	1990	2090	1990	2090
<i>TMAX</i>	204.4	246.4	80.6	89.17	139.6	173.4	260.0	312.8
<i>TMIN</i>	103.0	144.0	60.46	71.6	58.76	91.94	142.7	194.4
<i>TDIF</i>	101.4	102.4	44.68	40.85	66.1	70.49	132.9	132.7
<i>PSUP</i>	9912.0	9916.0	70.07	69.48	9866.0	9868.0	9958.0	9962.0
<i>QSUP</i>	0.0096	0.0117	0.0024	0.0031	0.0079	0.0096	0.0111	0.014
<i>T850.00</i>	92.69	137.4	62.53	69.78	47.34	85.63	129.8	183.2
<i>A850.00</i>	1511.0	1533.0	56.34	50.86	1481.0	1504.0	1549.0	1565.0
<i>Q850.00</i>	0.0052	0.0066	0.0022	0.0030	0.0037	0.0044	0.0066	0.0087
<i>T500.00</i>	-156.0	-92.01	48.82	48.65	-193.4	-127.4	-114.4	-51.93
<i>A500.00</i>	5692.0	5800.0	108.3	103.4	5621.0	5736.0	5778.0	5878.0
<i>Q500.00</i>	0.0013	0.0020	7.07e-4	0.0011	7.52e-4	0.0012	0.0017	0.0026
<i>A85/50.00</i>	-4181	-4267	77.57	81.17	-4243	-4332	-4122	-4207
<i>T85/50.00</i>	248.7	229.4	36.86	43.33	223.7	199.9	269.2	253.8

Tabla 5.19: Momentos y cuartiles de las variables simuladas por CGCM1 en los periodos 1990-2000 y 2090-2100.

fríos, y *T500.00*, para la que el incremento más notable estaría en los meses de Invierno.

El rango diario de temperatura no mostraría cambios importantes respecto a los valores generados para 1990-2000, ver figura 5.29.

Se produciría un aumento de un 10% en la desviación típica de las temperaturas de superficie y en el nivel geopotencial 850hPa; este incremento de la variabilidad se refleja también en que la variación del tercer cuartil en el periodo 2090-2100 es superior en 1°C al cambio indicado para el valor medio.

- El comportamiento de la presión no cambiaría de una manera sistemática en el escenario propuesto para finales del s. XXI, ni en la posición central, con valores medios mínimos en la época veraniega, ni en su dispersión, ver figura 5.30.
- Para la humedad específica se proyecta un incremento en el valor medio en todos los niveles geopotenciales, manteniendo el perfil estacional, véase como ejemplo el suavizado de la humedad en 500hPa en la figura 5.31. El incremento es mayor, en términos relativos, cuanto mayor es la altura: en el nivel 500hPa la media anual aumentaría un 53.1%, en 850hPa un 26.3% y en superficie un 22.5%. La variabilidad sería también mayor en el periodo 2090-2100 en todos los niveles. Esto corres-

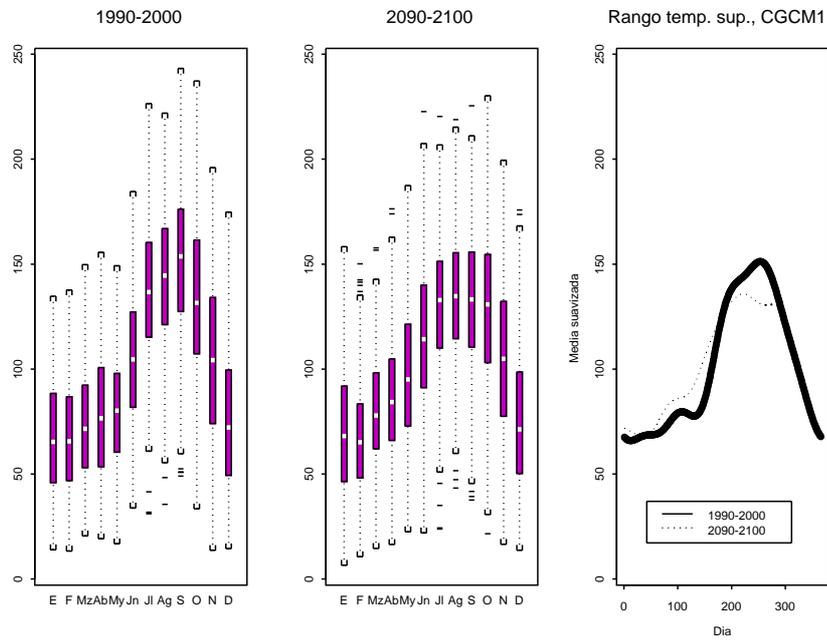


Figura 5.29: Diagramas de caja por meses y suavizado de los datos de rango diario de temperatura, generados por CGCM1 en los periodos 1990-2000 y 2090-2100.

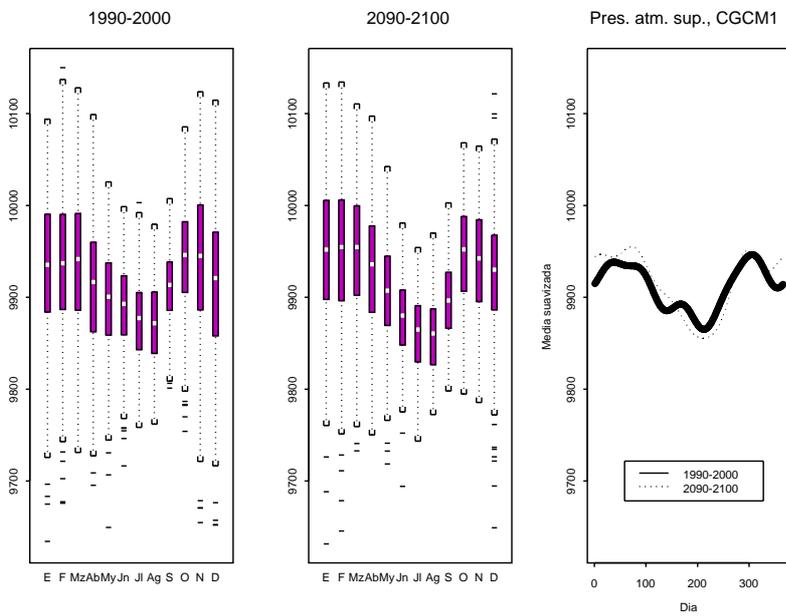


Figura 5.30: Diagramas de caja por meses y suavizado de los datos de presión atmosférica en superficie, generados por CGCM1 en los periodos 1990-2000 y 2090-2100.

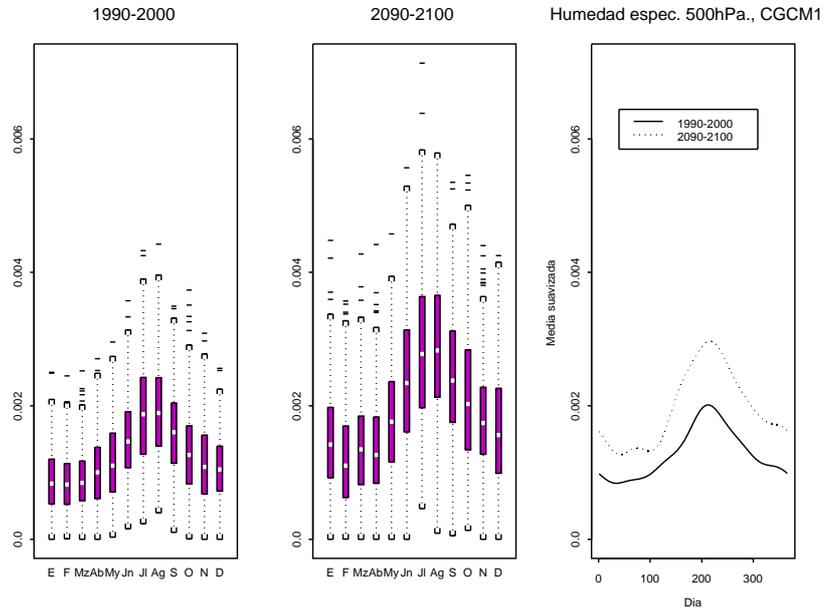


Figura 5.31: Diagramas de caja por meses y suavizado de los datos de humedad específica en el geopotencial 500hPa, generados por CGCM1 en los periodos 1990-2000 y 2090-2100.

ponde con la situación expuesta por expertos del cambio climático, que señalan que un escenario de incremento de temperatura provocaría el incremento de la evapotranspiración y, por consiguiente, de la cantidad de vapor de agua en la atmósfera.

- Habría un incremento de la altura del nivel 850hPa, que no se produciría homogéneamente a lo largo del año, ver figura 5.32; en los meses fríos se observaría un cambio de unos 20 metros en los parámetros de posición, ver tabla 5.19. En el nivel 500hPa el incremento sería mayor, alrededor de 100 metros, y constante a lo largo del año. Los cambios en el espesor de la capa 850-500hPa vendrían dominados por los del nivel 500hPa, ver figura 5.33.

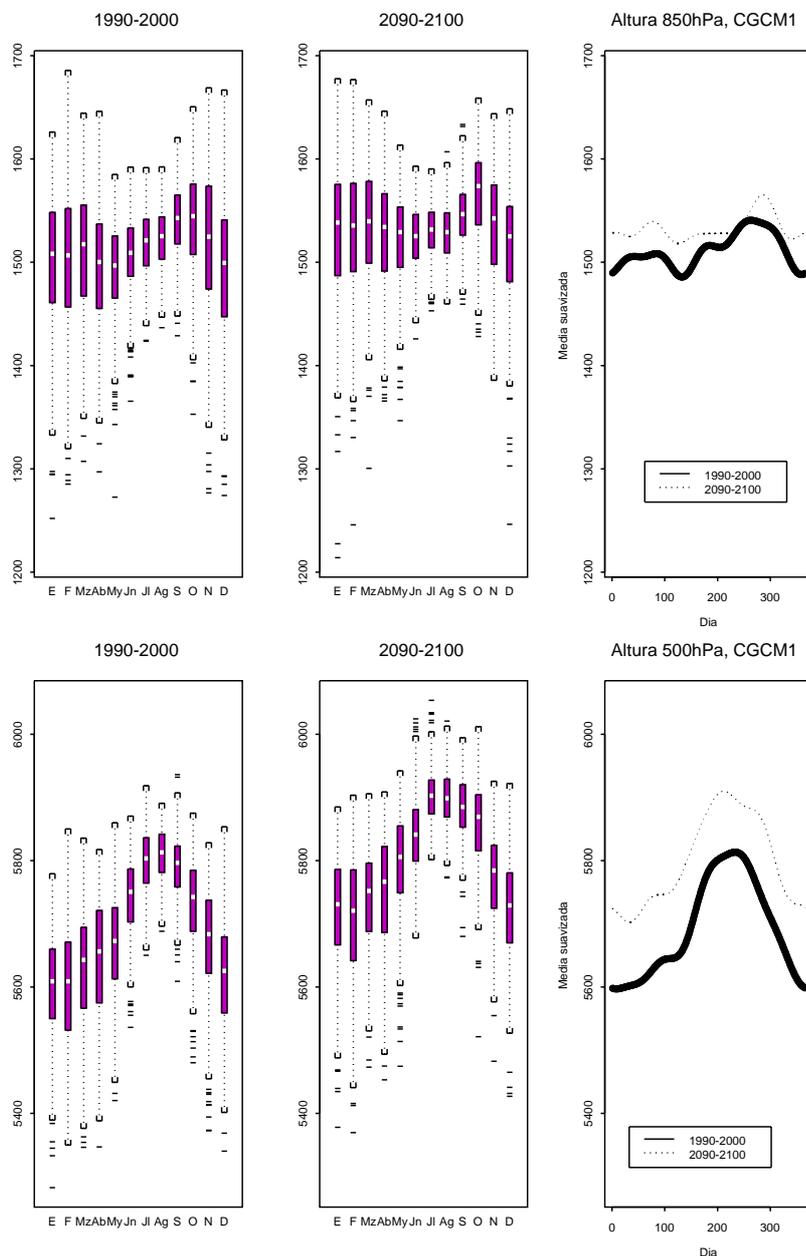


Figura 5.32: Diagramas de caja por meses y suavizado de los datos de altura del nivel geopotencial 850hPa y del nivel 500hPa, generados por CGCM1 en los periodos 1990-2000 y 2090-2100.

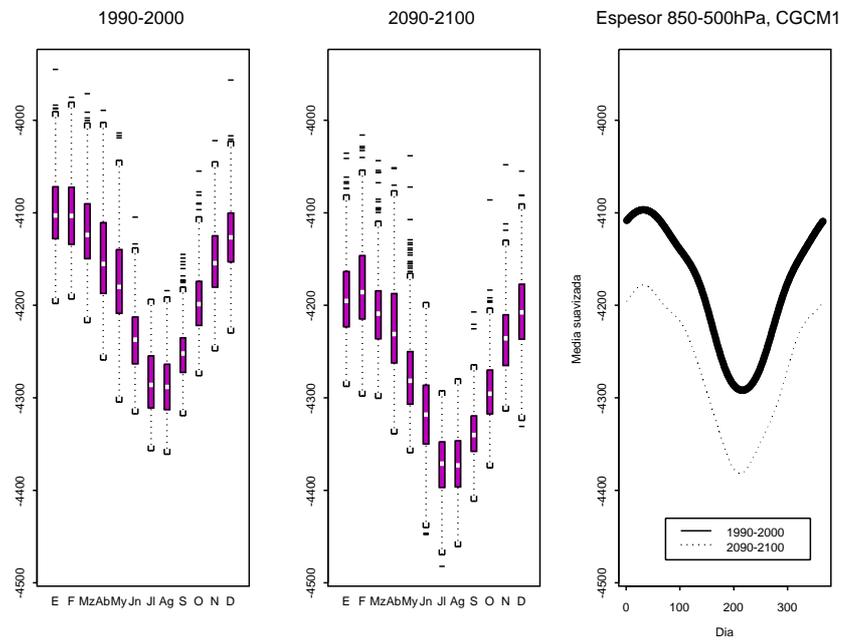


Figura 5.33: Diagramas de caja por meses y suavizado de los datos de espesor de la capa 850-500hPa, generados por CGCM1 en los periodos 1990-2000 y 2090-2100.

Estadístico	Observ.	Cov. observadas	Cov. CGCM1 2090-2100
Media	0.225	0.227	0.233
Desv. tip.	0.418	0.263	0.280
$Q_1$	0.000	0.026	0.017
$Q_3$	0.000	0.351	0.378

Tabla 5.20: Características de la frecuencia de lluvia observada y de las probabilidades ajustadas por *Down2*, con los datos observados y los generados por CGCM1 para el periodo 2090-2100.

### 5.10.2 Downscaling con el modelo *Down2* usando los datos de CGCM1 para el periodo 2090-2100

La utilidad última de los modelos estudiados en este capítulo es producir escenarios para la precipitación, en las condiciones de cambio climático. Vamos a utilizar el modelo *Down2* para establecer los cambios en la lluvia diaria en el horizonte 2090-2100, apoyándonos en la salida del experimento GHG+A de CGCM1, desarrollado de acuerdo con el escenario IS92a.

En la tabla 5.20 aparecen algunas medidas descriptivas de la frecuencia de lluvia observada y de las probabilidades ajustadas con los datos generados por el GCM en ese escenario. La proporción de días lluviosos ajustada para el periodo 2090-2100 es semejante a la frecuencia observada en 1990-2000 y a la ajustada por el modelo usando los datos observados en ese periodo. Sin embargo, su distribución a lo largo del año es muy diferente: la frecuencia de precipitación experimenta una fuerte reducción en los meses de Marzo a Junio, ver figura 5.34, mientras se incrementa fuertemente en el mes de Septiembre y, en menor medida, en los de Agosto y Octubre.

La simulación de 20 trayectorias del modelo permite valorar las alteraciones en la distribución de las longitudes de las rachas secas y húmedas. En la tabla C.43 se muestran los percentiles de las longitudes de racha seca obtenidas, que se comparan con los de las rachas secas observadas. Encontramos resultados que concuerdan con el régimen estacional proyectado: en los meses de Abril, Mayo, Junio y Septiembre, el test KS resulta significativo al 5%. Hay una reducción significativa de la mediana en el mes de Septiembre, asociada al incremento de la frecuencia de lluvia en esta época, y aumentos significativos en los de Mayo y Junio, cuando se hace más rara la precipitación.

En las longitudes de racha húmeda, ver tabla C.44, los resultados siguen el mismo esquema: en el test de Wilcoxon hay diferencias significativas, al 5%,

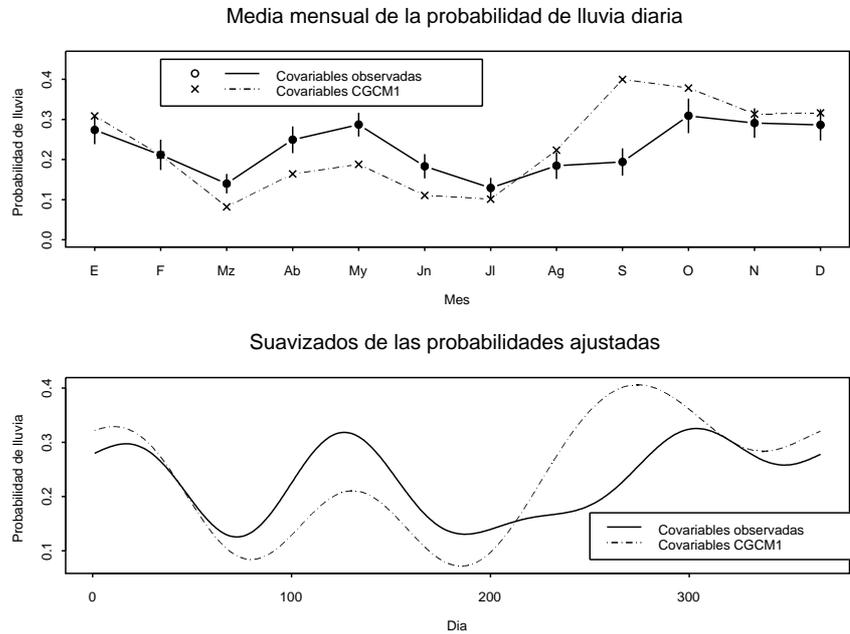


Figura 5.34: Probabilidades ajustadas por el modelo *Down2* con los datos observados y con los generados por CGCM1 para 2090-2100. Sup.: Valores medios mensuales. Inf.: Suavizados de los valores diarios.

en los meses entre Febrero y Mayo, cuando las rachas proyectadas tienden a ser más cortas, y se incrementa la mediana de las rachas simuladas en Septiembre. En el mes de Marzo se obtiene un rango intercuartílico simulado estrecho, el tercer cuartil está muy próximo a 1 día y, por lo tanto, un 75% de los episodios corresponden a días de lluvia aislados.

Las simulaciones permiten valorar también la distribución de las cantidades de lluvia positiva. La figura 5.35 muestra que los mayores cambios se producen en dos épocas, los meses de Primavera, Abril de manera destacada, y el mes de Agosto, en las que se simula un incremento de la intensidad de las precipitaciones. En los demás meses las medias simuladas son semejantes y, en todo los casos, se encuentran separadas menos de dos desviaciones típicas del valor medio observado.

La distribución de las cantidades positivas simuladas es muy diferente de la observada en la mayoría de los meses, ver tabla C.45. Las distribuciones, según el test KS, no son significativamente distintas al 5% en el mes de Marzo y al 1%, además, en los de Junio, Julio y Octubre. En los meses entre Noviembre y Febrero la distribución simulada tiene menor valor mediano y está más concentrada que la observada, mientras que en Abril, Mayo y

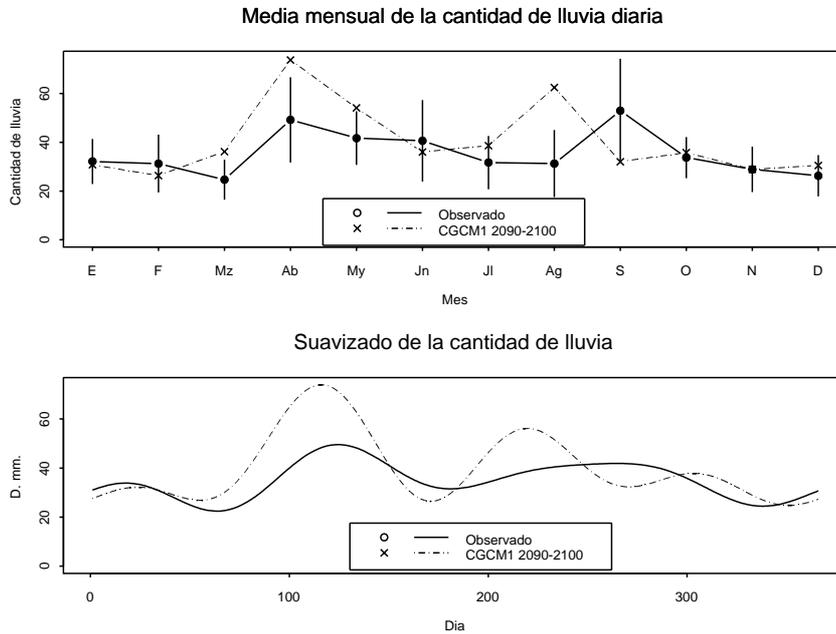


Figura 5.35: Valores medios de las cantidades positivas observadas y simuladas por el modelo *Down2* usando las covariables generadas por CGCM1 para 2090-2100. Sup.: Valores medios mensuales. Inf.: Suavizado de los valores diarios.

Agosto ocurre lo contrario.

El régimen de lluvia proyectado se puede valorar, de forma agregada, analizando la tabla 5.21. El escenario previsto para la precipitación tendría las siguientes características:

- Anualmente, los cambios en la frecuencia proyectada serían poco relevantes y habría un incremento de la cantidad de lluvia acumulada; sin embargo, la modificación del régimen estacional de lluvia sería notable.
- La frecuencia de lluvia disminuiría en Primavera un 37% respecto a lo que proyecta el modelo para la época actual. Esta estación pasaría a tener una frecuencia de lluvia similar a la que tiene actualmente el Verano.

La pérdida del carácter húmedo de la Primavera se refleja también en el valor medio de la cantidad de lluvia acumulada; es la única estación para la que se proyecta una cantidad menor que el valor medio actual. La reducción sería menos relevante que la expresada para la ocurrencia, porque en esos meses aumentaría la intensidad de los episodios lluviosos.

Nº medio días lluvia					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Simul.	84.8	25.1	13.2	13.6	32.9
% cambio	3.23	14.1	-41.3	-9.33	44.5
% cambio GCM 1990-2000	4.3	16.2	-36.5	-6.8	36.0
Media cantidad acumulada					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	2920.0	648.0	906.0	518.0	850.0
Simul.	3260.0	745.0	764.0	686.0	1070.0
% cambio	11.7	14.8	-15.7	32.4	25.5
% cambio GCM 1990-2000	19.0	20.0	-5.2	40.9	30.5

Tabla 5.21: Régimen de precipitación observado y obtenido en la simulación del modelo *Down2* utilizando los datos generados por CGCM1 para 2090-2100.

- En Verano se proyecta una ligera reducción de la frecuencia y un aumento de la cantidad acumulada, consecuencia del incremento de la intensidad en Agosto.
- El Otoño tendría precipitaciones más frecuentes que en el régimen actual y un incremento, menos notable, del valor medio de la cantidad acumulada.
- El Invierno sería algo más húmedo que en la actualidad, debido a un incremento de la frecuencia de lluvia.
- En síntesis, el régimen de precipitación mostraría una época húmeda, constituida por el Otoño y el Invierno, con mayor frecuencia de lluvia que la actual y una cantidad acumulada superior en un 20%. Por otro lado habría una época seca, formada por el periodo entre Marzo y Agosto, donde el número de días de precipitación sería más escaso y la cantidad acumulada equivalente a la actual. La aportación total de lluvia entre los meses de Agosto y Octubre superaría la de Primavera.

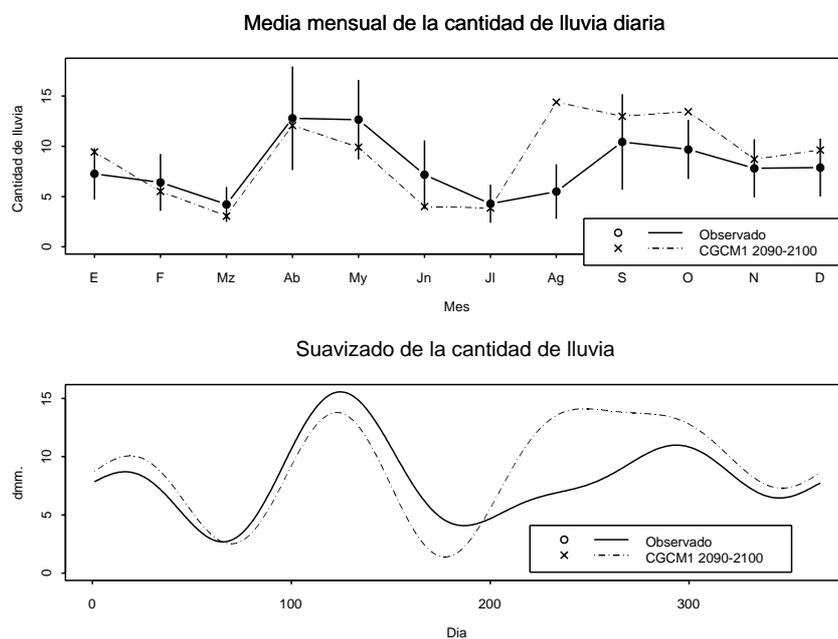


Figura 5.36: Valores medios de las cantidades observadas y simuladas por *Down2* usando las covariables generadas por CGCM1 para 2090-2100. Sup.: Valores medios mensuales. Inf.: Suavizado de los valores diarios.

### 5.10.3 Downscaling de la precipitación con otros modelos

Para finalizar esta sección vamos a comparar la proyección obtenida usando *Down2*, con las obtenidas directamente de CGCM1 y mediante downscaling con dos modelos, *Down1* y uno que no utiliza la información de humedad.

En la figura 5.37 superior izquierda, se muestra la proyección dada por la salida de CGCM1 para la celda que contiene a Zaragoza. Es preciso insistir en que la lluvia que propone para 1990-2000 no se corresponde con la observada en Zaragoza, ni en intensidad ni en su comportamiento estacional. En coincidencia con el resultado del downscaling con *Down2*, la salida del GCM indica una disminución de la lluvia en Primavera, de un 27% respecto a la cantidad simulada por él mismo para 1990-2000; por el contrario, no pronostica el incremento de la precipitación en Verano e Invierno que propone *Down2*.

La simulación de 20 trayectorias de lluvia para el periodo 2090-2100 a partir de *Down1* proporciona los resultados que se resumen en la tabla 5.22. Dado que su uso en el downscaling de la lluvia en el periodo actual resultó

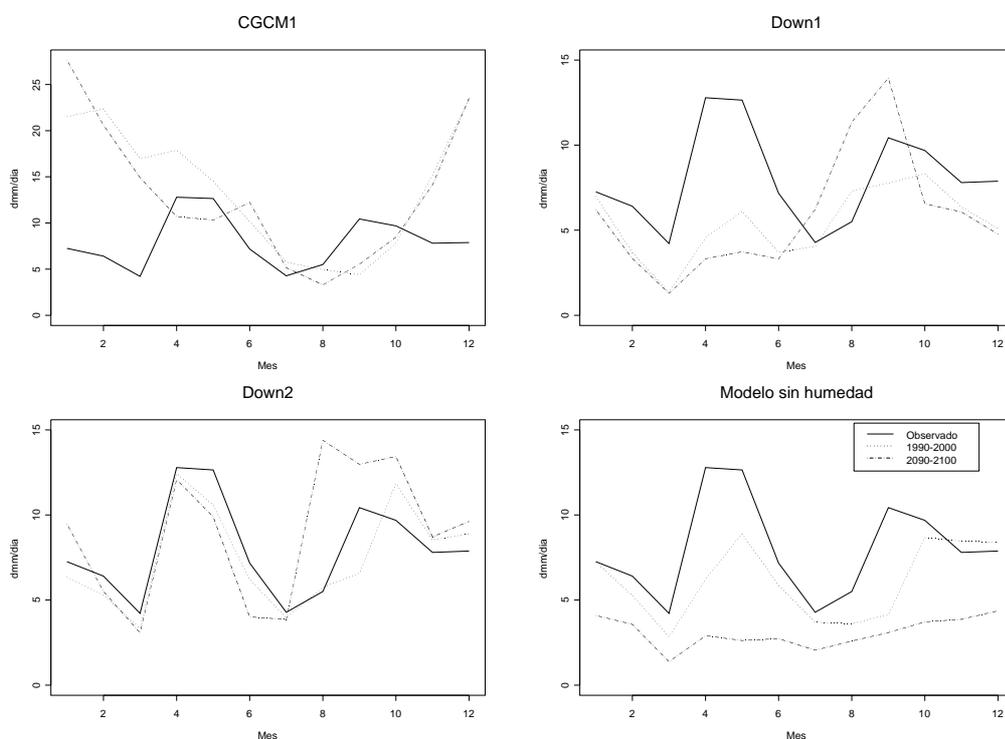


Figura 5.37: Valores medios, por meses, de la cantidad diaria de lluvia observada, generada por CGCM1 para la celda que contiene a Zaragoza, obtenida del downscaling de *Down1*, *Down2* y un modelo sin información de humedad, usando la salida de CGCM1 para los periodos 1990-2000 y 2090-2100.

poco satisfactorio, para evitar la influencia de los sesgos del modelo, la comparación se hace con los valores que proyecta para el periodo 1990-2000. A continuación se señalan las coincidencias y discrepancias con los resultados basados en *Down2*, ver tablas 5.21 y 5.22:

1. La Primavera pierde también su carácter de estación húmeda. La frecuencia de lluvia disminuye en la proyección un 38% pero los dos modelos discrepan en cuanto a la intensidad: *Down1* no proyecta el incremento que señala *Down2*, de modo que la cantidad acumulada disminuye un 31%.
2. En Verano los dos modelos proyectan un comportamiento análogo. *Down1* pronostica un descenso de la frecuencia de lluvia de un 8% y un aumento de la intensidad que hace que la lluvia global se incremente en un 40%.
3. Las discrepancias en las proyecciones para el Invierno son muy impor-

Nº medio días lluvia					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Simul.	60.4	16.5	9.7	13.6	20.6
% cambio	-26.5	-25.1	-56.9	-9.24	-9.59
% cambio GCM 1990-2000	-23.1	-22.9	-37.8	-8.11	-22.8
Media cantidad acumulada					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	2920.0	648.0	906.0	518.0	850.0
Simul.	2140.0	433.0	255.0	644.0	803.0
% cambio	-26.9	-33.3	-71.8	24.3	-5.57
% cambio GCM 1990-2000	7.54	-9.22	-30.9	39.1	17.7

Tabla 5.22: Régimen de precipitación observado y obtenido en el downscaling con *Down1* a partir de los datos de CGCM1 para el periodo 2090-2100.

tantes; el signo del cambio, tanto en la frecuencia como en la cantidad acumulada, es distinto en los dos modelos.

4. En Otoño *Down1* proyecta una disminución en la frecuencia de lluvia, contrariamente a lo que propone *Down2*. El incremento en la cantidad de lluvia global se debe a un aumento de la intensidad, que no pronostica *Down2*.

### Comparación con un modelo que no utiliza información de humedad

Con el fin de valorar la sensibilidad del downscaling a las covariables utilizadas en el modelo, se ha efectuado una proyección con un modelo en el que se han retirado las variables de humedad en todos los niveles de altura. Los predictores lineales incluyen el efecto de  $z.TMIN$ ,  $z.TDIF$ ,  $z.PSUP$ ,  $z.A850.00$ ,  $z.A500.00$ ,  $z.T500.00$  y  $z.T85/50.00$ , ver tablas C.46 y C.47.

El modelo produce un ajuste comparable al de *Down2*, ver tabla 5.23; el submodelo de ocurrencia explica un 31% de la variabilidad, 7 puntos menos que *Down2*, y el de cantidad un 30%, valor muy superior al 15% de *Down2*. Su proyección con los datos de CGCM1 para 1990-2000 presenta sesgos graves en la cantidad acumulada de todas las estaciones, salvo en Invierno.

Las proyecciones de este modelo para el final del s. XXI indican una reducción muy fuerte de la precipitación en todas las estaciones, de un 43% en la cantidad de lluvia acumulada como mínimo, siendo la más destacada

la de Primavera. Esta proyección es muy alarmante y está dirigida por los importantes incrementos pronosticados para la temperatura que tiene un efecto negativo en los predictores.

Frente a este pronóstico, la proyección de *Down2* es más fiable, ya que reproduce bien el régimen de lluvia del periodo 1990-2000, y menos dramática. Vemos pues que las proyecciones de la lluvia en una situación de cambio climático son muy sensibles a la información introducida en el modelo y concluimos que éstos deben basarse en variables de distinto tipo, bien representadas, capaces de recoger los distintos efectos que influyen en la precipitación.

% variabilidad explicada por el modelo					
	Global	Invierno	Primav.	Verano	Otoño
Global	34.59	39.45	22.48	31.87	38.19
Ocurrencia	31.21	34.2	23.87	29.74	32.88
Cantidad	29.6	35.45	17.44	27.92	28.63
Valores ajustados por el modelo, con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	80.8	21.2	20.3	15.2	24.0
%cambio	-1.69	-3.61	-9.97	1.34	5.55
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	2770.0	684.0	832.0	548.0	703.0
%cambio	-5.2	5.45	-8.18	5.91	-17.3
Valores ajustados por el modelo, con los datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primavera	Verano	Otoño
Proyección 1990-2000	78.7	22.6	18.5	14.2	23.3
%cambio	-4.17	2.47	-17.8	-5.34	2.62
Media cantidad acumulada					
Proyección 1990-2000	2230.0	632.0	550.0	402.0	647.0
%cambio	-23.5	-2.48	-39.3	-22.3	-23.9
Valores ajustados por el modelo, con los datos del GCM para 2090-2100					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primavera	Verano	Otoño
Proyección 2090-2100	55.2	15.1	9.42	12.3	18.3
%cambio	-32.7	-31.5	-58.2	-17.6	-19.5
%cambio GCM 1990-2000	-29.9	-33.2	-49.1	-13.4	-21.5
Media cantidad acumulada					
Proyección 2090-2100	1120.0	362.0	211.0	226.0	323.0
%cambio	-61.5	-44.2	-76.7	-56.4	-62.0
%cambio GCM 1990-2000	-49.8	-42.7	-61.6	-43.8	-50.1

Tabla 5.23: Régimen de precipitación observado y ajustado por el modelo de lluvia que no utiliza información de humedad, usando los datos observados y los generados por CGCM1 para los periodos 1990-2000 y 2090-2100.

## 5.11 Conclusiones y líneas de investigación abiertas

En esta sección se resumen las conclusiones sobre el procedimiento de downscaling propuesto y se presentan las líneas de trabajo en las que se pretende continuar buscando la mejora de los modelos utilizados.

### 5.11.1 Conclusiones sobre el procedimiento de downscaling propuesto

El método de downscaling propuesto en este capítulo se ha mostrado una herramienta válida para realizar la proyección de la lluvia diaria en escenarios de cambio climático. Antes de entrar a valorarlo, queremos señalar dos aspectos cuestionables:

1. Una propiedad inherente a los métodos estadísticos de downscaling es la invariancia de la relación entre precipitación y variables atmosféricas, recogida en el predictor lineal en el caso de los modelos de regresión, que se considera permanecerá inalterada en la situación de cambio climático.

Una rigidez de los modelos ajustados en este capítulo consiste que el perfil estacional de la lluvia está básicamente asociado al efecto de los armónicos, que permanece invariante en el periodo 2090-2100. Los posibles cambios en la estacionalidad sólo pueden introducirse, en este momento, a través de los cambios proyectados en las anomalías de las variables atmosféricas, lo que ha ocurrido en el downscaling con *Down2*. Esta rigidez desaparecerá, en buena parte, cuando introduzcamos en el modelo variables bien representadas por el GCM.

2. En la modelización estadística se hace la hipótesis de que las covariables introducidas en los predictores lineales representan la señal, climática en nuestro caso, y que la variabilidad no explicada tiene un comportamiento aleatorio. Hemos visto, sin embargo, que los modelos de lluvia útiles para el downscaling no pueden incluir variables que son significativas en los modelos del capítulo 3, cuya influencia global puede tener un signo determinado.

La solución a este problema está fuera del alcance de nuestra investigación; como en el apartado anterior, ese posible sesgo desaparecerá gradualmente según los GCM vayan representando de modo adecuado algunas variables influyentes, que en la actualidad no podemos utilizar.

Una vez analizados los modelos ajustados y tras realizar una comparación con otros métodos de downscaling discutidos en la sección 5.3, se pueden señalar algunas ventajas de la metodología que proponemos:

- El grado de reproducción de la climatología de Zaragoza por parte de las variables generadas por el GCM se analiza en la escala diaria, la misma escala temporal que se usará en el downscaling. En la literatura abundan los estudios parciales que se limitan a comparar las medias mensuales o estacionales, ver Beckmann y Buishand (2001) [20].
- Los modelos de regresión que hemos seleccionado son más dúctiles que los basados en la clasificación de tipos de clima, Goodess (2000) [50]. Los puntos débiles de éstos son superados por el método propuesto en este capítulo:
  - Existe la posibilidad de usar cualquier variable bien representada por el GCM frente al uso exclusivo de la información de presión. La presión atmosférica es una variable para la que se proyectan cambios poco relevantes en los escenarios de cambio climático, por lo que el downscaling basado en ella da lugar a proyecciones con pequeños cambios. Para incrementar la sensibilidad del downscaling es necesario incluir otras covariables, bien representadas, que recojan las diferentes facetas del cambio proyectado en la situación de calentamiento.
  - Las salidas de nuestro modelo, probabilidad de ocurrencia y cantidad de lluvia esperada, toman valores en un rango continuo, mientras que las de los modelos basados en los tipos de clima lo hacen en un conjunto finito. El hecho de que las características de la lluvia diaria dependan sólo del tipo de clima reinante representa una discretización de las variables atmosféricas continuas que supone una pérdida de información.
- Se ha alcanzado el objetivo planteado de construir modelos de lluvia que contengan la información disponible, relevante para el fenómeno.

En la búsqueda de un modelo de lluvia apropiado para el downscaling hemos comprobado la relevancia de la humedad específica, en el nivel 500hPa y en superficie. Cabe recordar que Beckmann y Buishand (2001) [20] insisten en la necesidad de incluir alguna variable que represente la situación de humedad de la atmósfera, ellos en particular utilizan la humedad específica en el nivel 700hPa y el agua precipitable.

Otra variable importante en los modelos ajustados, no utilizada habitualmente en la literatura, ha sido el rango diario de temperatura.

- La adecuación del modelo para el downscaling se decide, tras verificar su validez y calidad, a partir del análisis de su comportamiento cuando se utiliza con las variables generadas por el GCM en la situación climática actual; dada la finalidad del modelo, consideramos indispensable que presente sesgos mínimos respecto del régimen observado.
- La modelización propuesta permite obtener series simuladas de lluvia diaria de las que se pueden extraer conclusiones tanto del comportamiento agregado, por estaciones o anualmente, como de aspectos de la escala diaria; por ejemplo, la persistencia del fenómeno, la distribución de las longitudes de racha y de las cantidades registradas, los datos extremos, etc.

En este sentido cabe recordar que *Down2*, cuando se utiliza con los datos generados por el GCM para el clima actual, reproduce adecuadamente la distribución de las longitudes de rachas secas y húmedas y las frecuencias en cada mes; el submodelo de cantidad reproduce satisfactoriamente los valores medios de la cantidad recogida en un día húmedo en todos los meses y, en la mitad de ellos, también su distribución.

- Como conclusión final importante cabe señalar que la metodología empleada ha permitido realizar de forma satisfactoria el downscaling de la precipitación a partir de los datos generados por CGCM1, un modelo que tiene menor resolución espacial que otros GCM disponibles. El incremento paulatino de esa resolución en futuras versiones o modelos permitirá que lleguen a representarse adecuadamente más variables locales; en ese momento, el procedimiento de downscaling que proponemos mejorará su sensibilidad y resultados.

### 5.11.2 Líneas de investigación abiertas

La necesidad de utilizar métodos estadísticos para cubrir las carencias actuales de los GCM en la representación de la lluvia a escala regional o local, nos lleva a considerar de gran interés proseguir con la investigación en este tema y mejorar sus resultados.

En primer lugar nos referiremos a los trabajos que realizaremos a corto plazo, relativos a la mejora de los modelos utilizados y a la construcción de uno alternativo basado en covariables seleccionadas con un criterio distinto al usado para construir *Down1* y *Down2*. Posteriormente se presentan otras líneas de trabajo que se deben desarrollar a medio plazo.

#### Otros criterios de selección de las potenciales covariables

Consideramos necesario realizar una discusión acerca del criterio utilizado en la selección de las covariables potenciales del modelo *Down1* y confrontarlo con otros criterios diferentes, basados también en las conclusiones de la comparación realizada en la subsección 5.6.1; el objetivo es valorar qué modelos estadísticos alternativos pueden surgir.

Comencemos por recordar las razones que llevaron a la selección de las covariables para *Down1*: Decidimos considerar útiles aquellas anomalías que producían, con el test KS, p-valores mayores que 0.01 en seis, al menos, de los doce meses. La mala representación de la dirección del viento nos llevó a prescindir de esa información, dado que en los modelos estudiados en el capítulo 3 el viento se introducía a través de su dirección y velocidad. Las covariables potenciales para construir el modelo *Down2* estuvieron determinadas por la selección hecha para *Down1*.

En la tabla 5.24 se señalan las anomalías seleccionadas para construir los modelos *Down1* y *Down2*. Se indica entre paréntesis los modelos en los que han resultado significativas (Oc se refiere al submodelo de ocurrencia y C al de cantidad). En el caso de *Down2*, se señalan, con la correspondiente letra inicial en minúscula, las estaciones en que intervienen. En la tabla se muestran también las variables seleccionadas aplicando tres criterios alternativos:

- El criterio A, que consiste en seleccionar como covariables potenciales sólo aquellas que tienen en el test KS p-valores mayores que 0.05 en los tres meses de la estación.
- El criterio B que se basa en los resultados del test global aplicado a cada estación y variable, ver tabla 5.7, usando los niveles de significación

Variable	<i>Down1</i>	<i>Down2</i>	Criterio A	Criterio B	Criterio C
<i>z.TMIN</i>	X (Oc,C)	i,p (Oc:i,p)	i	i,p	i,p
<i>z.TDIF</i>	X (Oc,C)	i,v,o (Oc:i,v,o; C:i)	i,v	X	i,v
<i>z.PSUP</i>	X (Oc,C)	X (Oc)	i	X	X
<i>z.QSUP</i>	X (Oc,C)	i,v,o (Oc:i,v,o; C:v)	i,v	X	i,v,o
<i>z.T850.00</i>				o	o
<i>z.A850.00</i>	X (Oc,C)	X (Oc, C)	X	X	X
<i>z.Q850.00</i>	X	X (Oc)	i,v	X	X
<i>z.T500.00</i>	X	X (Oc)		i,p,v	p,v
<i>z.A500.00</i>	X (Oc)	p,v (Oc:p,v; C:p,v)		i,p,v	p,v
<i>z.Q500.00</i>	X (Oc)	X (Oc, C)	i,v,o	X	X
<i>z.T85/50.00</i>	X	X (C)	i	X	i,p
<i>z.A85/50.00</i>				v	v
<i>z.USUP</i>				p	
<i>z.VSUP</i>				p,o	p,o
<i>z.U850.00</i>			i,p	X	i,p,o
<i>z.V850.00</i>			i	X	X
<i>z.U500.00</i>				X	i,o
<i>z.V500.00</i>			p,v,o	X	X
<i>PSUP</i>				i	
<i>Q850.00</i>				i	
<i>Q500.00</i>			o	i,v,o	i,v,o
<i>T85/50.00</i>				i	
<i>U850.00</i>				p,v,o	p,o
<i>U500.00</i>				o	
<i>V500.00</i>				o	

Tabla 5.24: Anomalías y variables seleccionadas como covariables candidatas en los modelos *Down1* y *Down2* y según otros criterios.

$$\alpha = \alpha^G = 0.01.$$

- El criterio C, análogo a B, que usa los niveles de significación  $\alpha = \alpha^G = 0.05$ .

El criterio B es más laxo que C y éste, a su vez, menos estricto que A. Con el criterio A se dispone de menos información que la utilizada para construir *Down1* pero resulta interesante establecer cuál es el grado de ajuste que puede alcanzarse si se emplean sólo aquellas variables que superan el control de igualdad en todos los meses; por otra parte, se encuentran entre ellas algunas variables no utilizadas previamente.

El criterio C selecciona la mayoría de las variables elegidas por B. Nos parece más adecuado que éste porque prescinde del uso de *z.TDIF*, *z.QSUP* y *z.A500.00* en las estaciones en las que provocan sesgos, como comprobamos en el downscaling con *Down1*. Por contra, C impide en algunas estaciones el uso de las anomalías de las componentes U del viento en los dos niveles geopotenciales.

La principal diferencia entre los criterios B y C y la selección hecha para formular *Down1* radica en que aquéllos admiten el uso de anomalías de las componentes de viento y de algunas variables en ciertas estaciones. La incorporación de esta información, sin duda relevante para explicar la respuesta, hace especialmente prometedores los modelos que surjan de esta selección.

A corto plazo definiremos la metodología de construcción de un modelo que, de acuerdo con el criterio C, utilice información de las componentes de viento; estableceremos una estrategia para analizar la interacción entre esas componentes, o sus anomalías, que deben reflejar las existentes en los modelos del capítulo 3, entre la situación del viento en superficie y en el geopotencial 500hPa.

### **Líneas de investigación a medio plazo**

A medio plazo nos planteamos dos líneas de trabajo, una de ellas se refiere al desarrollo de ideas que permitan mejorar este método de downscaling y aplicarlo de una forma generalizada. La otra corresponde a explotarlo para obtener conclusiones sobre impactos del cambio climático en la disponibilidad de recursos hídricos o en la variabilidad de fenómenos extremos. Este último es uno de los objetivos propuestos en el proyecto de investigación REN2002-00009 'Análisis espacio-temporal de la variabilidad de la precipitación diaria y del cambio a largo plazo de la precipitación en España. Modelización

de sus episodios extremos en la Cuenca del Ebro', que debe desarrollarse hasta Octubre de 2005 y para el que el Ministerio de Ciencia y Tecnología ha asignado financiación. El desarrollo de estas dos líneas de investigación implica cuatro actuaciones:

1. En cuanto a las modificaciones técnicas de los actuales modelos:
  - Estudiaremos las ventajas de construir modelos diferenciados para cada época del año, en particular para el Verano, con el fin de alcanzar una mejor reproducción de las características diarias de la lluvia. El modelo de cantidad resulta menos satisfactorio que el de ocurrencia, por lo que debemos hacer un esfuerzo por mejorarlo, construyendo, por ejemplo, ajustes con parámetro de dispersión distinto en cada estación.
  - Vamos a ajustar dos modelos estadísticos que permiten generar series sintéticas de lluvia diaria en una situación de cambio climático:
    - El modelo de cadena oculta de Markov para la serie de ocurrencia diaria, que tiene especial interés porque sustituye, mediante un proceso estocástico, información relevante no disponible, una situación habitual que, en nuestro caso, corresponde a la existencia de covariables influyentes que no podemos utilizar debido a su mala representación.
    - Ensayaremos un modelo que considera tres estados de ocurrencia: seco, húmedo y uno intermedio denominado traza, correspondiente a observar precipitación por debajo de un umbral. De acuerdo con esta descripción, el estado del proceso de ocurrencia cada día es una realización de una variable trinomial cuyas probabilidades de transición se pueden ajustar mediante un modelo loglineal.  
Este modelo puede evitar los problemas encontrados en la representación de las cantidades positivas pequeñas; por otra parte, el downscaling basado en observatorios no profesionales puede obligarnos a trabajar con series, homogéneas y de calidad, que no registran con rigor las cantidades pequeñas.
2. Para hacer posible la aplicación del método de downscaling en cualquier región apoyándose en observatorios no profesionales, vamos a construir modelos estadísticos usando los datos del reanálisis NCEP/NCAR. Esto incrementará la información disponible y permitirá definir variables

derivadas que representan la situación atmosférica, como la baroclinicidad o la vorticidad, ver Beckmann y Buishand (2001) [20].

Existen dos alternativas para construir modelos con esta información:

- a) Trabajar con las series de las variables correspondientes a ese punto, obtenidas mediante un procedimiento de interpolación a partir de los valores que proporciona el reanálisis en los puntos de su red que rodeen al observatorio. Esto requiere desarrollar un procedimiento de interpolación capaz de reproducir óptimamente los valores que se han producido en el punto de interés.
- b) Utilizar como covariables los datos del reanálisis en una colección de puntos de la red, lo que significa ampliar el conjunto de información. Esto nos obligará a reorganizar el protocolo de análisis de la significación de las variables y hará más costosa la modelización.

Con los datos del reanálisis NCEP/NCAR (primera versión) de la celda que contiene a Zaragoza y de las situadas al Norte y Oeste de ella, se ha ajustado ya un modelo empleando la alternativa b), Mateo (2003) [88]; este modelo preliminar alcanza porcentajes de variabilidad explicada menores que los modelos ajustados en este capítulo, construidos con medidas registradas in situ.

3. Debemos aplicar el método de downscaling con datos generados por otros GCM con la finalidad de analizar la sensibilidad de las proyecciones a la utilización de distinta información. Además, nos interesa utilizar las salidas de experimentos en una variedad de escenarios SRES, actualmente los escenarios de referencia para el IPCC, de modo que sus proyecciones establezcan los límites entre los que puede encontrarse, verosímilmente, el cambio en la precipitación. Aunque ya indicamos nuestras dificultades para obtener datos diarios de los distintos modelos, es presumible que en un futuro cercano este problema se haya solucionado.
4. En cuanto a la explotación de nuestro método de downscaling, en el plazo de un año y medio pensamos comenzar a desarrollar dos vías:
  - Debemos implementar un método que proporcione proyecciones de los recursos hídricos disponibles en algunas subcuencas de la cuenca del Ebro en un escenario de cambio climático. Concretamente analizaremos la disponibilidad de agua a partir de la simulación de series diarias del flujo en la cabecera de algunos afluentes del

Ebro. Utilizaremos un modelo de aforos, de la Confederación Hidrográfica del Ebro, en el que las entradas serán las series diarias de temperatura generadas por un GCM y la serie diaria de precipitación resultante del downscaling en observatorios situados en esa subcuenca.

- Analizaremos el efecto del cambio climático sobre los extremos pluviométricos.

A partir de las series diarias de lluvia simuladas por el proceso de downscaling se pueden construir índices diseñados para evaluar la variabilidad de los extremos climáticos como, por ejemplo, los propuestos en el proyecto europeo STARDEX (Statistical and Regional dynamical Downscaling of Extremes for European regions), coordinado por Clare Goodess, que pueden encontrarse en la página

<http://www.cru.uea.ac.uk/cru/projects/stardex/>

Por otra parte, la metodología propuesta para realizar el downscaling de la lluvia diaria es adaptable para realizar el downscaling y proyectar algunos procesos de extremos. Por ejemplo, en el caso de la sequía, se tiene un proceso constituido por una variable binaria que indica su ocurrencia y, si existe un estado de sequía, variables que representan su intensidad; este marco es similar al del proceso de lluvia con el que hemos trabajado en este capítulo.

# Bibliografía

- [1] Abaurrea, J., Asín, J., y Cebrián, A. C. (1994). Ajuste de Modelos Estocásticos de Lluvia usando GLIM. *Actas de las III Jornadas Zaragoza-Pau de Matemática Aplicada y Estadística*. Univ. Zaragoza, pag. 27-37.
- [2] Abaurrea, J., Asín, J., y Cebrián, A. C. (1995). Modelización de series de datos pluviométricos diarios. Comunicación en la I Reunión del Grupo de Predicción Dinámica. Granada.
- [3] Abaurrea, J., y Asín, J. (1997). Consecuencias en la precipitación de los escenarios de cambio climático. *Actas del XXIII Congreso de la SEIO*.
- [4] Abaurrea, J., y Asín, J. (1997). Evaluación del impacto de un cambio de temperaturas en el régimen de precipitación mediante un modelo para la lluvia diaria. *Actas de la VI Conferencia Española de Biometría*. Univ. Córdoba, pag. 268-280.
- [5] Abaurrea, J., y Asín, J. (1999). Modelización de la ocurrencia de lluvia en ausencia de covariables de interés. *Actas V Jornadas Zaragoza-Pau de Matemática Aplicada y Estadística*. Univ. Zaragoza, pag. 29-36.
- [6] Abaurrea, J., y Asín, J. (1999). Un modelo hidden-Markov para una serie de ocurrencia diaria de precipitación. Comunicación en la VII Conferencia Española de Biometría, Palma de Mallorca.
- [7] Abaurrea, J., y Asín, J. (1999). Comparación de modelos hidden-Markov para la ocurrencia de precipitación. Comunicación en las VI Jornadas Zaragoza-Pau de Matemática Aplicada y Estadística, Jaca.
- [8] Abaurrea, J., y Asín, J. (2001). Downscaling daily rainfall through its relationship with other meteorological covariates. Comunicación en las VII Jornadas Zaragoza-Pau de Matemática Aplicada y Estadística, Jaca.
- [9] Abaurrea, J., Asín, J., Erdozain, O., y Fernández, E. (2001). Climate variability analysis of temperature series in the Medium Ebro River

- Basin. En López, D., y Brunet, M. (ed.) (2001). *Detecting and Modelling Regional Climate Change*, pag. 109-118. Springer.
- [10] Abaurrea, J., Asín, J., y Centelles, A. (2002). Caracterización espacio-temporal de la evolución de la precipitación anual en la cuenca del Ebro. En Guijarro, J. A., Grimalt, M., Laita, M., y Alonso, S. (ed.) (2002). *El Agua y el Clima*, pag. 113-124. Asociación Española de Climatología.
- [11] Aitkin, M., Anderson, D., Francis, B., y Hinde, J. (1992). *Statistical Modelling in GLIM*. Oxford University Press.
- [12] Almarza, C., López, J. A., y Flores, C. (1996). *Homogeneidad y variabilidad de los registros históricos de precipitación de España*. Dirección General del Instituto Nacional de Meteorología, Ministerio de Medio Ambiente.
- [13] Almarza, C., López, J. A., Garrido, I., Gil, M. D., Lafuente, J. A., Chazarra, A., Fernández, L., y Sánchez, J. (2000). *Valores normales de precipitación y temperatura de la Red Climatológica (1961-1990)*. Dirección General del Instituto Nacional de Meteorología, Ministerio de Medio Ambiente.
- [14] Anderson, D. A., y Aitkin, M. (1985). Variance Component Models with Binary Response: Interviewer Variability. *JRSS B*, 47, pag. 203-210.
- [15] Armengot, R., Abellán, J. J., y Pérez-Cueva, A. J. (2001). Evaluación de un modelo de regresión logística de lluvias intensas en territorio valenciano con el episodio de octubre de 2000. En Pérez-Cueva, A. J., López Baeza, E., Tamayo, J. (ed.) (2001). *El Tiempo del Clima*, pag. 291-301. Publicaciones de la Asociación Española de Climatología (AEC), Serie A, número 2.
- [16] Bandeen-Roche, K., Miglioretti, D. L., Zeger, S. L., y Rathouz, P. J. (1997). Latent Variable Regression for Multiple Discrete Outcomes. *JASA*, 92, 440, pag. 1375-1386.
- [17] Bardossy, A., y Caspary, H. J. (1990). Detection of Climate Change in Europe by Analyzing European Atmospheric Circulation Patterns from 1881 to 1989. *Theoretical and Applied Climatology*, n. 42, pag. 155-167.
- [18] Bardossy, A., y Plate, E. (1991). Modeling daily rainfall using a semi-Markov representation of circulation pattern occurrence. *Journal of Hydrology*, 122, pag. 33-47.

- [19] Bardossy, A., y Plate, E. J. (1992). Space-Time Model for Daily Rainfall Using Atmospheric Circulation Patterns. *Water Resour. Res.*, 28, pag. 1247-1259.
- [20] Beckmann, B. R., y Buishand, T. A. (2001). *KNMI contribution to the European project WRINCLE: downscaling relationships for precipitation for several European sites*. KNMI, De Bilt.
- [21] Bellone, E., Hughes, J. P., y Guttorp, P. (2000). A hidden Markov model for downscaling synoptic atmospheric patterns to precipitations amounts. *Climate Research*, 15, pag. 1-12.
- [22] Brandsma, T., y Buishand, T. A., (1997). Statistical linkage of daily precipitation in Switzerland to atmospheric circulation and temperature. *Journal of Hidrology*, 198, pag. 98-123.
- [23] Buishand, T. A. (1977). *Stochastic Modelling of daily rainfall sequences*. Tesis doctoral. Wageningen.
- [24] Buishand, T. A., y Klein Tank, A. M. G. (1996). Regression model for generating time series of daily precipitation amounts for climate change impact studies. *Stochastic Hydrology and Hydraulics*, 10, n. 2, pag. 87-106.
- [25] Butler, S. M., y Louis, T. A. (1997). Consistency of maximum likelihood estimators in general random effects models for binary data. *The Annals of Statistics*, 25, n. 1, pag. 351-377.
- [26] Cavazos, T. (2000). Using Self-Organizing Maps to Investigate Extreme Climate Events: An Application to Wintertime Precipitation in the Balkans. *Journal of Climate*, vol. 13, pag. 1718-1732.
- [27] Colomer, M. A. (1995). *Modelización numérico-estocástica para simular series de precipitación y temperaturas diarias. Aplicación en la provincia de Lleida*. Tesis doctoral, sin publicar.
- [28] Collett, D. (1991). *Modelling binary data*. Chapman & Hall.
- [29] Cowpertwait, P. S. P. (1991). Further Developments of the Neyman-Scott Clustered Point Process. *Water Resour. Res.*, 27, pag. 1431-1438.
- [30] Cowpertwait, P. S. P. (1994). A generalized point process model for rainfall. *Proc. R. Soc. Lond. A*, 447, pag. 23-47.

- [31] Cowpertwait, P. S. P., O'Connell, P. E., Metcalfe, A. V., y Mawdsley, J. A. (1996). Stochastic point process modelling of rainfall. I. Single-site fitting and validation. *Journal of Hydrology*, 175, pag. 17-46.
- [32] Cowpertwait, P. S. P., O'Connell, P. E., Metcalfe, A. V., y Mawdsley, J. A. (1996). Stochastic point process modelling of rainfall. II. Regionalisation and disaggregation. *Journal of Hydrology*, 175, pag. 47-65.
- [33] Cox, D. R., e Isham, V. (1994). Stochastic Models of Precipitation. En Barnett, V., y Turkman, K. F. (ed.) (1994). *Statistics for the Environment 2: Water Resources Issues*, pag. 3-18, Wiley.
- [34] Chang, T. J., Kavvas, M. L., y Delleur, J. W. (1984). Daily Precipitation Modeling by Discrete Autorregressive Moving Average Processes. *Water Resour. Res.*, 20, pag. 565-580.
- [35] Del Hoyo, J., Fernández, A., Mestre, A., y Peral, C. (2002). *Sistema de predicción analógica de la precipitación del INM (PAP-INM)*. Nota técnica del Servicio de Aplicaciones Meteorológicas. Ministerio de Medio Ambiente.
- [36] Dietz, E., y Böhning, D. (1995). Statistical Inference Based on a General Model of Unobserved Heterogeneity. En Seeber, G. U. H., Francis, B. J., Hatzinger, R., y Steckel-Berger, G. (ed.) (1995). *Statistical Modelling. L. N. S.* 104, pag. 75-82. Springer.
- [37] Diggle, P. J., Liang, K.-Y., y Zeger, S. L. (1994). *Analysis of Longitudinal Data*. Oxford University Press.
- [38] Dobson, A. J. (2002). *An Introduction to Generalized Linear Models*. Chapman and Hall.
- [39] Entekhabi, D., Rodríguez Iturbe, I., y Eagleson, P. S. (1989). Probabilistic Representation of the Temporal Rainfall process by a Modified Neyman-Scott Rectangular Pulses Model: Parameter Estimation and Validation. *Water Resour. Res.*, 25, pag. 295-302.
- [40] Fahrmeir, L., y Tutz, G. (1994). *Multivariate Statistical Modelling. Based in Generalized Linear Models*. Springer-Verlag.
- [41] Flato, G. M., Boer, G. J., Lee, W. G., McFarlane, N. A., Ramsden, D., Reader, M. C., y Weaver, A. J. (2000). The Canadian Centre for Climate Modelling and Analysis Global Coupled Model and its Climate. *Climate Dynamics*, 16, pag. 451-467.

- [42] Foufoula-Georgiou, E., y Lettenmaier, D. P. (1987). A Markov renewal model for rainfall occurrences. *Water Resour. Res.*, 23, pag. 875-884.
- [43] García de Pedraza, L. (1985). *La Predicción del Tiempo en el Valle del Ebro*. Editado por el Ministerio de Transportes, Turismo y Comunicaciones. Dirección Gral. del INM.
- [44] García Vera, M. A., Abaurrea, J., Asín, J., y Centelles, A. (2002). Evolución de las precipitaciones en la cuenca del Ebro: caracterización espacial y análisis de tendencias. *Actas de la VII Reunión Nacional de Climatología*, pag. 99-108.
- [45] Gaver, D. P., y Lewis, P. A. W. (1980). First-order autorregresive gamma sequences and point processes. *Adv. Appl. Prob.*, 12, pag. 727-745.
- [46] Glasbey, C. A., y Nevison, I. M. (1997). Rainfall Modelling Using a Latent Gaussian Variable. En Gregoire, T. G., Brillinger, D. R., Diggle, P. J., Russek-Cohen, E., Warren, W. G., y Wolfinger, R. D. (ed.) (1997). *Modelling longitudinal and spatially correlated data: Methods, applications and future directions*. *L. N. S.*, 122, pag. 233-242. Springer.
- [47] González-Rouco, J. F., Heyen, H., Zorita, E., y Valero, F. (2000). Agreement between Observed Rainfall Trends and Climate Change Simulations in the Southwest of Europe. *Journal of Climate*, vol. 13, pag. 3057-3065.
- [48] González Hidalgo, J. C., De Luis, M., y Raventós, J. (2002). Variaciones estacionales de la precipitación en la costa este peninsular durante la década de los años noventa. En Guijarro, J. A., Grimalt, M., Laita, M., y Alonso, S. (ed.) (2002). *El Agua y el Clima*, pag. 229-236. Asociación Española de Climatología.
- [49] Goodess, C. M., y Palutikof, J. P. (1998). Development of daily rainfall scenarios for Southeast Spain using a circulation approach to downscaling. *Int. J. of Climat.*, 10, pag. 1051-1083.
- [50] Goodess, C. M. (2000). *The construction of daily rainfall scenarios for Mediterranean sites using a circulation-type approach to downscaling*. University of East Anglia, PhD Thesis.
- [51] Gregoire, T. G., Brillinger, D. R., Diggle, P. J., Russek-Cohen, E., Warren, W. G., y Wolfinger, R. D. (ed.) (1997). *Modelling longitudinal and spatially correlated data: Methods, applications and future directions*. *L. N. S.*, 122. Springer.

- [52] Grunwald, G. K., y Jones, R. H. (2000). Markov models for time series with mixed distribution. *Environmetrics*, 11, pag. 327-339.
- [53] Gyasi-Agyei, Y. (1999). Identification of regional parameters of a stochastic model for rainfall disaggregation. *Journal of Hydrology*, 223, pag. 148-163.
- [54] Gyasi-Agyei, Y., y Willgoose, G. R. (1999). Generalisation of a hybrid model for point rainfall. *Journal of Hydrology*, 219, pag. 218-224.
- [55] Hand, D., y Crowder, M. J. (1996). *Practical Longitudinal Data Analysis*. Chapman and Hall.
- [56] Hay, L. E., McCabe, G. J. Jr., Wolock, D. M., y Ayers, M. A. (1991). Simulation of Precipitation by Weather Type Analysis. *Water Resour. Res.*, 27, pag. 493-501.
- [57] Hengeveld, H. G. (2000). *Projections for Canada's climate future. A discussion of recent simulations with the Canadian Global Climate Model*. Meteorological Service of Canada. Minister of Public Works and Government Services. Canadá.
- [58] Hosmer, D. W., y Lemeshow, S. (1989). *Applied Logistic Regression*. Wiley.
- [59] Houghton, J. T., Jenkins, G. J., y Ephraums, J. J. (ed.) (1990). *Climate Change: The IPCC Scientific Assessment*. Cambridge University Press.
- [60] Houghton, J. T., Callander, B. A., y Varney, S. K. (ed.) (1992). *Climate Change 1992*. Cambridge University Press.
- [61] Houghton, J. T., Callander, B. A., y Varney, S. K. (ed.) (1992). *Climate Change 1992: The Supplementary Report to the IPCC Scientific Assessment*. Cambridge University Press.
- [62] Houghton, J. T., Meira Filho, L. G., Bruce, J., Lee, H., Callander, B. A., Haites, E., Harris, N., y Maskell, K. (ed.) (1995). *Climate Change 1994: Radiative Forcing of Climate Change and an Evaluation of the IPCC IS92 Emission Scenarios*. Cambridge University Press.
- [63] Houghton, J. T., Meira Filho, L. G., Callander, B. A., Harris, N., Katzenberg, A., y Maskell, K. (ed.) (1996). *Climate Change 1995. The Science of Climate Change*. Cambridge University Press.

- [64] Houghton, J. T., Ding, Y., Griggs, D. J., Noguera, M., van der Linden, P. J., Dai, X., Maskell, K., y Johnson, C. A. (ed.) (2001). *Climate Change 2001: The Scientific Basis. Contribution of Working Group I to the Third Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press.
- [65] Hughes, J. P., y Guttorp, P. (1994). Incorporating Spatial Dependence and Atmospheric Data in a Model of Precipitation. *J. of Applied Meteorology*, 33, pag. 1503-1515.
- [66] Hughes, J. P., y Guttorp, P. (1994). A class of stochastic models for relating synoptic atmospheric pattern to regional hydrologic phenomena. *Water Resour. Res.*, 30, pag. 1535-1546.
- [67] Hughes, J. P., Guttorp, P., y Charles, S. P. (1999). A non-homogeneous hidden Markov model for precipitation occurrence. *Appl. Statist.*, 48, part 1, pag. 15-30.
- [68] IPCC-TG CIA (1999). *Guidelines on the Use of Scenario Data for Climate Impact and Adaptation Assessment*. Version 1. Carter, T. R., Hulme, M., y Lal, M. IPCC, Task Group on Scenarios for Climate Impact Assessment. En la red [http://ipcc-ddc.cru.uea.ac.uk/cru\\_data/support/guidance.pdf](http://ipcc-ddc.cru.uea.ac.uk/cru_data/support/guidance.pdf)
- [69] Jimoh, O. D., y Webster, P. (1996). The optimum order of a Markov chain model for daily rainfall in Nigeria. *Journal of Hydrology*, 185, pag. 45-69.
- [70] Jimoh, O. D., y Webster, P. (1999). Stochastic modelling of daily rainfall in Nigeria: intra-annual variation of model parameters. *Journal of Hydrology*, 222, pag. 1-17.
- [71] Jolliffe, I. T., y Hope, P. B. (1996). Representation of daily rainfall distributions using normalized rainfall curves. *Int. J. of Climat.*, 16, pag. 1157-1163.
- [72] Johnson, N. L., Kotz, S., y Balakrishnan, N. (1994). *Continuous univariate distributions*, vol. 1. Wiley.
- [73] Jothiyangkoon, C., Sivapalan, M., y Viney, N. R. (2000). Tests of a space-time model of daily rainfall in southwestern Australia based on nonhomogeneous random cascades. *Water Resour. Res.*, 36, pag. 267-284.

- [74] Katz, R. W., y Parlange, M. B. (1995). Generalizations of chain-dependent processes: Applications to hourly precipitation. *Water Resour. Res.*, 31, pag. 1331-1341.
- [75] Kavvas, M. L., Deller, J. W., y Entekhabi, D. (1989). Probabilistic Representation of the Temporal Rainfall process by a Modified Neyman-Scott Rectangular Pulses Model: Parameter Estimation and Validation. *Water Resour. Res.*, 25, pag. 295-302.
- [76] Kilsby, C. G., Buishand, T. A., y Jones P. D. (2000). Production of precipitation scenarios for impact assessment of climate change in Europe. WRINCLE report. En la red <http://www.ncl.ac.uk/wrinclereports/Popsicle.pdf>.
- [77] Klein Tank, A. M. G., y Buishand, T. A. (1995). *Transformation of precipitation time series for climate change impact studies*. KNMI, De Bilt.
- [78] Kottegoda, N. T., Natale, L., y Raiteri, E. (2000). Statistical modelling of daily streamflow using rainfall input and curve number technique. *J. of Hydrology*, 234, pag. 170-186.
- [79] Laird, N. M. (1996). Longitudinal panel data: an overview of current methodology. En Cox, D. R., Hinkley, D. V. y Barndorff-Nielsen, O. E. (ed.) (1996). *Time Series Models. In econometrics, finance and other fields*. Chapman & Hall.
- [80] Legates, D. R., y McCabe, G. J. (1999). Evaluating the use of goodness-of-fit measures in hydrologic and hydroclimatic model validation, *Water Resour. Res.*, 35, pag. 233-241.
- [81] Lettenmaier, D. (1995). Stochastic Modeling of Precipitation with Applications to Climate Model Downscaling. En von Storch, H., y Navarra, A., (ed.) (1995). Cap. 11, *Analysis of Climate Variability. Applications and Statistical Techniques*. Springer.
- [82] Lindsey, J. K. (1992). *The Analysis of Stochastic Processes using GLIM. L. N. S.*, 72. Springer-Verlag.
- [83] Lindsey, J. K. (1993). *Models for Repeated Measurements*. Oxford Science Publications.
- [84] Lindsey, J. K. (1997). *Applying Generalized Linear Models*. Springer.

- [85] López, D., y Brunet, M. (ed.) (2001). *Detecting and Modelling Regional Climate Change*. Springer.
- [86] MacDonald, I. L., y Zucchini, W. (1997). *Hidden Markov and Other Models for Discrete-valued Time Series*. Chapman and Hall.
- [87] Martín-Vide, J., y Gómez, L. (1999). Regionalization of Peninsular Spain based on the length of dry spells. *Int. J. Climat.*, 19, pag. 537-555.
- [88] Mateo, M. (2003). *Construcción de un método estadístico de downscaling para la precipitación local*. Proyecto final de carrera para la obtención del título de Ingeniero en Telecomunicación, sin publicar.
- [89] McCullagh, P., y Nelder, J. A. (1989). *Generalized Linear Models*. Chapman & Hall.
- [90] Moberg, A., y Alexandersson, H. (1997). Homogenization of Swedish temperature data. Part II: Homogenized gridded air temperature compared with a subset of global gridded air temperature since 1861. *Int. J. Climat.*, 17, pag. 35-54.
- [91] Moon, S.-E., Ryoo, S.-B., y Kwon, J.-G. (1994). A Markov chain model for daily precipitation occurrence in South Korea. *Int. J. Climat.*, 14, pag. 1009-1016.
- [92] Murphy, J. (2000). Predictions of climate change over Europe using statistical and dynamical downscaling techniques. *Int. J. Climatol.*, 20, pag. 489-501.
- [93] Nakicenovic, N., y Swart, R. (ed.) (2000). *IPCC Special Report on Emissions Scenarios*. Cambridge University Press.
- [94] Onof, C., y Wheeler, H. S. (1993). Modelling of British rainfall using a random parameter Bartlett-Lewis Rectangular Pulse Model. *Journal of Hydrology*, 149, pag. 67-95.
- [95] Pierce, D. A., y Schafer, D. W. (1986). Residuals on Generalized Linear Models. *JASA*, 81, 396, pag. 977-986.
- [96] Ribalaygua, J., Borén, R., y Balairón, L. (1996). Clasificación de repartos de precipitación diaria sobre la España Peninsular y Baleárica: Aplicación para la generación de clasificaciones atmosféricas de apoyo a la predicción de precipitaciones. *Actas IV Simposio Nacional de Predicción*. Editado por el INM.

- [97] Riha, S. J., Wilks, D. S., y Simoens, P. (1996). Impact of temperature and precipitations variability on crop model predictions. *Climate Change*, 32, pag. 293-311.
- [98] Rodríguez Iturbe, I., Cox, D. R., e Isham, V. (1987). Some models for rainfall based on stochastic point processes. *Proc. R. Soc. Lond., A* 410, pag. 269-288.
- [99] Rodríguez Iturbe, I., Cox, D. R., e Isham, V. (1988). A point process model for rainfall: further developments. *Proc. R. Soc. Lond., A* 417, pag. 283-298.
- [100] Rodríguez-Puebla, C., Frías, M. D., y Encinas, A. H. (2001). Relationships between dry and wet periods in spring precipitation over the Iberian peninsula and atmospheric circulation. En López, D., y Brunet, M. (ed.) (2001). *Detecting and Modelling Regional Climate Change*, pag. 397-404. Springer.
- [101] Romero, R., Sumner, G., Ramis, C., y Genovés, A. (1999). A classification of the atmospheric circulation patterns producing significant daily rainfall in the Spanish Mediterranean area. *Int. J. Climatol.*, 19, pag. 765-785.
- [102] Sánchez Rodríguez, J. (1993). *Situaciones atmosféricas en España*. Editado por el Ministerio de Obras Públicas, Transportes y Medio Ambiente. Dirección Gral. del INM.
- [103] Semenov, M., y Barrow, E. M. (1997). Use of a stochastic weather generator in the development of climate change scenarios. *Climate Change*, 35, pag. 397-414.
- [104] Serrano, A., García, J. A., Mateos, V. L., Cancillo, M. L., y Garrido, J. (1999). Monthly Modes of Variation of Precipitation over the Iberian Peninsula. *Journal of Climate*, 12, pag. 2894-2919.
- [105] Sharma, T. C. (1996). Simulation of the Kenyan longest dry and wet spells and the largest rain-sums using a Markov model. *Journal of Hydrology*, 178, pag. 55-67.
- [106] Smith, J. A. (1987). Statistical modeling of daily rainfall occurrences. *Water Resour. Res.*, 23, pag. 885-893.
- [107] Smith, R. L. (1994). Spatial Modelling of Rainfall Data. En Barnett, V., y Turkman, K. F. (ed.). *Statistics for the Environment II*, pag. 19-41. Wiley.

- [108] Stern, R. D., y Coe, R. (1984). A Model Fitting Analysis of Daily Rainfall Data. *J. R. Statist. Soc., A*, 147, pag. 1-34.
- [109] Sugimoto, S., Nakakita, E., e Ikebuchi, S. (2001). A stochastic approach to short-term rainfall prediction using a physically based conceptual rainfall model. *Journal of Hydrology*, 242, pag. 137-155.
- [110] Sumner, G. N., Romero, R., Homar, V., Ramis, C., Alonso, S., y Zorita, E. (2003). An estimate of the effects of climate change on the rainfall of Mediterranean Spain by the late twenty first century. *Climate Dynamics*, 20, pag. 789-805.
- [111] Tudela, J. C. (1999). *Rosas de vientos de observatorios meteorológicos principales. Zaragoza Aeropuerto (periodo 1987-96)*. Editado por la Secretaria Gral. Técnica del Ministerio de Medio Ambiente.
- [112] von Storch, H., y Navarra, A. (ed.) (1995). *Analysis of Climate Variability. Applications of Statistical Techniques*. Springer-Verlag.
- [113] von Storch, H., y Zwiers, F. W. (1999). *Statistical Analysis in Climate Research*. Cambridge University Press.
- [114] Waymire, E., y Gupta, V. K. (1981). The mathematical structure of rainfall representations, 1. A review of the stochastic rainfall models. *Water Resour. Res.*, 17, pag. 1261-1272.
- [115] Wilby, R. (1994). Stochastic weather type simulation for regional climate change impact assessment. *Water Resour. Res.*, 30, pag. 3395-3403.
- [116] Wilby, R. (1995). Simulation of precipitation by weather pattern and frontal analysis. *Journal of Hydrology*, 173, pag. 91-109.
- [117] Wilby, R. L., Wigley, T. M. L., Conway, D., Jones, P. D., Hewitson, B. C., Main, J., y Wilks, D. S. (1998). Statistical downscaling of general circulation model output: A comparison of methods. *Water Resour. Res.*, 34, pag. 2995-3008.
- [118] Wilby, R. L., Hay, L. E., y Leavesley, G. H. (1999). A comparison of downscaled and raw GCM output: implications for climate change scenarios in the San Juan River basin, Colorado. *Journal of Hydrology*, 225, pag. 67-91.
- [119] Wilby, R. L., y Wigley, T. M. L. (2000). Precipitation predictors for downscaling: observed and general circulation model relationships. *Int. J. Climatol.*, 20, pag 641-661.

- [120] Wilks, D. S. (1998). Multisite generalization of a daily stochastic precipitation generation model. *J. of Hydrology*, 210, pag. 178-191.
- [121] Woolhiser, D. A., Keefer, T. O., y Redmond, K. T. (1993). Southern Oscillation Effects on Daily Precipitation in the southwestern United States. *Water Resour. Res.*, 29, pag. 1287-1295.
- [122] Woolhiser, D. A., y Roldán, J. (1986). Seasonal and Regional Variability of Parameters for Stochastic Daily Precipitation Models: South Dakota, U.S.A. *Water Resour. Res.*, 22, pag. 965-978.
- [123] Woolhiser, D. A. (1992). Modeling daily precipitation - progress and problems. En Walden, A. T. y Guttorp, P. (ed.). *Statistics in the environmental & Earth sciences*, pag. 71-89. Edward Arnold.
- [124] Zeger, S. L., y Qaqish, B. (1988). Markov Regression Models for Time Series: A Quasi-Likelihood Approach. *Biometrics*, 44, pag. 1019-1031.
- [125] Zorita, E., y von Storch, H. (1999). The Analog Method as a Simple Statistical Downscaling Technique: Comparison with More Complicated Methods. *Journal of Climate*, 12, pag. 2474-2489.
- [126] Zucchini, W., y Guttorp, P. (1991). A Hidden Markov Model for Space-Time Precipitation. *Water Resour. Res.*, 27, pag. 1917-1923.
- 
-

# Apéndice A

## Tablas de los modelos condicionales

Este apéndice contiene las tablas que muestran el resultado de los modelos ajustados, de su evaluación en los periodos de estimación y validación. Aparecen, en primer lugar, los modelos de cadena de Markov ajustados para el proceso diario de ocurrencia de precipitación en Tortosa, Reinosa, Agoncillo y Zaragoza. Finalmente, se muestran las tablas de los modelos Gamma para la cantidad en un día con lluvia.

### A.1 Modelos de ocurrencia

**A.1.1 Tortosa**

Cadena de Markov homogénea			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-1.870	0.03241	-57.690
$Y_{t-1}$	1.627	0.05997	27.130
$Y_{t-2}$	0.3598	0.06882	5.229
$Y_{t-1} : Y_{t-2}$	-0.4116	0.1012	-4.066
$Y_{t-3}$	0.282	0.06586	4.282
$Y_{t-1} : Y_{t-3}$	-0.2818	0.1021	-2.761
$Y_{t-4}$	0.2196	0.05081	4.322
Cadena de Markov estacional			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-1.859	0.0325	-57.200
$Y_{t-1}$	1.616	0.06043	26.740
$Y_{t-2}$	0.3387	0.06909	4.902
$Y_{t-1} : Y_{t-2}$	-0.4394	0.1021	-4.304
$Y_{t-3}$	0.2702	0.06624	4.079
$Y_{t-1} : Y_{t-3}$	-0.3241	0.1032	-3.141
$Y_{t-4}$	0.184	0.05144	3.576
$S1$	0.06136	0.0422	1.454
$C1$	-0.03099	0.04251	-0.7292
$Y_{t-1} : S1$	0.024	0.06236	0.3848
$Y_{t-1} : C1$	0.2411	0.06578	3.666
$Y_{t-3} : S1$	0.01517	0.0705	0.2152
$Y_{t-3} : C1$	0.2291	0.07363	3.111
$Y_{t-4} : S1$	0.09919	0.07142	1.389
$Y_{t-4} : C1$	-0.1644	0.07405	-2.221
$S2$	-0.08298	0.03736	-2.221
$C2$	-0.06305	0.0371	-1.699
$Y_{t-1} : S2$	-0.05885	0.06413	-0.9177
$Y_{t-1} : C2$	-0.1294	0.06351	-2.037
$S3$	0.1063	0.03032	3.506
$C3$	0.08283	0.03021	2.742
$S4$	-0.06414	0.0301	-2.131
$C4$	0.01146	0.03027	0.3786
$S5$	-0.03382	0.0301	-1.123
$C5$	0.06995	0.03017	2.319

Tabla A.1: Modelos markovianos homogéneo y estacional para el proceso de ocurrencia en Tortosa.

Cadena de Markov con información de temperatura			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	1.024	0.1937	5.285
$Y_{t-1}$	3.069	0.2819	10.890
$Y_{t-2}$	0.3082	0.07238	4.257
$Y_{t-1} : Y_{t-2}$	-0.2991	0.109	-2.745
$Y_{t-3}$	0.2433	0.06902	3.524
$Y_{t-1} : Y_{t-3}$	-0.2288	0.110	-2.080
$Y_{t-4}$	0.1999	0.05416	3.692
$S1$	-0.08922	0.05583	-1.598
$C1$	-0.6474	0.08764	-7.387
$Y_{t-3} : S1$	-0.01479	0.07422	-0.1993
$Y_{t-3} : C1$	0.2359	0.07777	3.033
$Y_{t-4} : S1$	0.09345	0.07513	1.244
$Y_{t-4} : C1$	-0.1681	0.07784	-2.160
$S2$	-0.02945	0.04116	-0.7156
$C2$	-0.2365	0.03488	-6.780
$S3$	0.1361	0.03215	4.232
$C3$	0.03745	0.03183	1.176
$S4$	-0.05711	0.03164	-1.805
$C4$	0.02073	0.03172	0.6536
$S5$	-0.02399	0.03169	-0.7568
$C5$	0.07284	0.03162	2.303
$TDIF_t$	-0.02768	0.001089	-25.420
$Y_{t-1} : TDIF_t$	-0.04157	0.006555	-6.342
$Y_{t-1} : TDIF_t^2$	2.163e-4	3.784e-5	5.716
$TDIF_{t-1}$	0.008212	9.726e-4	8.444
$TMIN_t$	-0.01876	0.002165	-8.663
$TMIN_t^2$	1.898e-5	8.547e-6	2.220
$TMIN_{t-1}$	0.007723	0.001327	5.820

Tabla A.2: Modelo de cadena de Markov con información de temperatura ajustado en Tortosa.

		Deviance	Gr. lib.
Modelo nulo		15170.77	14412
Modelo ajustado		13953.68	14405
AIC:	13967.68	BIC:	14020.71
Estad. HL	-	p-valor	-
% variabilidad explicada por modelo			9.27
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	78.05
Primavera	Verano	Otoño	Invierno
74.3	82.13	78.39	77.29
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	84.51	55.06
	Húmedo	0	0
%NAS		Anual	0
Primavera	Verano	Otoño	Invierno
0	0	0	0
% días bien clasificados (frec. día)		Anual	69.46
Primavera	Verano	Otoño	Invierno
72.65	57.87	73.8	73.57
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	87.98	0
	Húmedo	12.97	100
%NAS		Anual	27.24
Primavera	Verano	Otoño	Invierno
32.05	18.6	29.04	32.15
Índice relativo de Brier		Anual	9.28
Primavera	Verano	Otoño	Invierno
9.81	3.61	9.91	11.3
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9947	Coef. eficiencia	0.6101
Índice de acuerdo	0.7945	% medio error	2.048
Días de precipitación observados y estimados por años			
Coef. correlación	0.998	Coef. eficiencia	0.617
Índice de acuerdo	0.799	% medio error	2.347

Tabla A.3: Medidas de bondad de ajuste de la cadena de Markov homogénea, Tortosa (1942-1981).

		Deviance	Gr. lib.
Modelo nulo		15170.77	14412
Modelo ajustado		13863.52	14387
AIC: 13913.52		BIC:	14102.92
Estad. HL	6.01	p-valor	0.65
% variabilidad explicada por modelo			9.96
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	78.12
Primavera	Verano	Otoño	Invierno
74.3	82.13	78.23	77.76
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	83.81
	Húmedo	0	20.6
%NAS		Anual	8.5
Primavera	Verano	Otoño	Invierno
14.34	1.07	6.27	9.08
% días bien clasificados (frec. día)		Anual	72.09
Primavera	Verano	Otoño	Invierno
71.94	69.63	74.11	72.68
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	91.96	0
	Húmedo	12.97	100
%NAS		Anual	29.07
Primavera	Verano	Otoño	Invierno
33.24	20.84	29.44	32.28
Índice relativo de Brier		Anual	9.97
Primavera	Verano	Otoño	Invierno
10.29	5.35	10.24	11.7
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9899	Coef. eficiencia	0.9797
Índice de acuerdo	0.9948	% medio error	0.1342
Días de precipitación observados y estimados por años			
Coef. correlación	0.9873	Coef. eficiencia	0.5981
Índice de acuerdo	0.786	% medio error	2.364

Tabla A.4: Medidas de bondad de ajuste de la cadena de Markov estacional, Tortosa (1942-1981).

		Deviance	Gr. lib.
Modelo nulo		15170.77	14412
Modelo ajustado		12690.25	14384
AIC:	12746.25	BIC:	12958.38
Estad. HL	1.64	p-valor	0.99
% variabilidad explicada por modelo			18.84
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	81.13
Primavera	Verano	Otoño	Invierno
79.67	83.54	81.42	79.87
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	99.6	80.08
	Húmedo	4.94	52.32
%NAS		Anual	23.39
Primavera	Verano	Otoño	Invierno
28.91	12.88	23.79	24.64
% días bien clasificados (frec. día)		Anual	70.75
Primavera	Verano	Otoño	Invierno
72.65	68.96	71.66	69.77
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	83.09	13.66
	Húmedo	41.1	94.51
%NAS		Anual	32.83
Primavera	Verano	Otoño	Invierno
39.49	26.47	32.04	32.94
Índice relativo de Brier		Anual	18.84
Primavera	Verano	Otoño	Invierno
24.08	13.84	18.07	16.78
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9953	Coef. eficiencia	0.9904
Índice de acuerdo	0.9975	% medio error	0.09995
Días de precipitación observados y estimados por años			
Coef. correlación	0.7758	Coef. eficiencia	0.5144
Índice de acuerdo	0.7637	% medio error	2.579

Tabla A.5: Medidas de bondad de ajuste de la cadena de Markov con información de temperatura, Tortosa (1942-1981).

Longitud	Rachas secas		Rachas húmedas	
	Observada	Ajustada	Observada	Ajustada
1	0.213	0.214	0.547	0.545
2	0.142	0.145	0.259	0.255
3	0.099	0.103	0.103	0.114
4	0.073	0.072	0.052	0.044
5	0.062	0.062	0.020	0.021
6	0.056	0.054	0.012	0.010
7	0.054	0.047	0.003	0.005
8	0.044	0.041	0.004	0.002
9	0.038	0.035	0.001	0.001
10	0.028	0.030	0.001	0.001
11	0.028	0.026	0	0
12	0.021	0.023	0	0
13	0.017	0.020	0	0
14	0.024	0.017	0	0
15	0.013	0.015	0	0
16	0.011	0.013	0	0
17	0.006	0.011	0	0
18	0.010	0.010	0	0
19	0.007	0.008	0	0
$\geq 20$	0.052	0.003	0	0
p-valor test $X^2$	0.111		0.012	

Tabla A.6: Distribuciones de las longitudes de racha observada y teórica según *CM hom*, Tortosa (1942-1981).

Rachas secas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor test $X^2$
1	6.47	3	7.33	6	0.781
2	6.43	4	7.25	7	0.531
3	5.96	4	5.97	7.5	0.701
4	5.43	3	5.32	6	0.711
5	5.01	3	5.16	6	0.398
6	6.56	4	7.08	7	0.646
7	9.01	6	9	8.5	0.009
8	6.39	4	5.98	7	0.267
9	6.54	5	6.01	7	0.218
10	6.25	4	6.24	5.75	0.591
11	8.12	6	8.58	9	0.263
12	6.44	4	8.2	6	0.888
Teórica	6.32	4	6.38	7	—
Rachas húmedas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor test $X^2$
1	1.78	1	1.16	1	0.981
2	1.97	1	1.47	1	0.712
3	1.94	2	1.17	1	0.373
4	1.89	1	1.25	1	0.542
5	1.94	1	1.42	1	0.529
6	1.65	1	0.89	1	0.367
7	1.47	1	0.76	1	0.083
8	1.5	1	0.88	1	0.013
9	1.88	1	1.32	1	0.889
10	1.92	1	1.43	1	0.067
11	1.74	1	1.02	1	0.643
12	2.01	2	1.39	1	0.014
Teórica	1.82	1	1.23	1	—

Tabla A.7: Distribuciones de las longitudes de racha observada y teórica según *CM hom*, por meses, Tortosa (1942-1981).

## Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 3	1	1	-	-
	Simul. 3.21	1.1	1.05	1	0.779
2	Obs. 4	1	1	-	-
	Simul. 3.45	1.38	1.2	1	0.941
3	Obs. 3	2	1	-	-
	Simul. 3.77	1.52	1.25	0.994	0.578
4	Obs. 4	1	1	-	-
	Simul. 3.42	1.25	1.2	1	0.893
5	Obs. 3	1	1	-	-
	Simul. 3.42	1.7	1.44	0.998	0.495
6	Obs. 3	1	1	-	-
	Simul. 2.95	1	1	0.929	0.31
7	Obs. 2	1	1	-	-
	Simul. 2.1	1	0.8	0.636	0.108
8	Obs. 2	1	1	-	-
	Simul. 2.75	1	1	0.977	0.409
9	Obs. 3.2	1	1	-	-
	Simul. 3.21	1.12	1.1	1	0.599
10	Obs. 4	1	1	-	-
	Simul. 3.65	1.35	1.21	0.494	0.379
11	Obs. 3	1	1	-	-
	Simul. 3.16	1.15	1.08	1	0.97
12	Obs. 4	2	1	-	-
	Simul. 3.63	1.52	1.31	0.997	0.723

## Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 16.1	3	6	-	-
	Simul. 16.54	4.65	7.54	0.224	0.103
2	Obs. 15	4	7	-	-
	Simul. 14.96	4.12	7.26	0.826	0.462
3	Obs. 14	4	7.5	-	-
	Simul. 14.59	3.75	6.7	0.999	0.767
4	Obs. 12	3	6	-	-
	Simul. 12.52	3.62	6.12	1	0.864
5	Obs. 11	3	6	-	-
	Simul. 11.27	2.9	4.79	0.621	0.467
6	Obs. 16	4	7	-	-
	Simul. 15.79	4.15	6.8	0.8	0.624
7	Obs. 19	6	8.5	-	-
	Simul. 18.06	5.4	8.66	0.162	0.07
8	Obs. 14	4	7	-	-
	Simul. 16.01	4.65	7.66	0.893	0.765
9	Obs. 14	5	7	-	-
	Simul. 13.98	4	6.39	0.089	0.12
10	Obs. 13.3	4	5.75	-	-
	Simul. 15.42	3.82	6.79	0.466	0.436
11	Obs. 19.6	6	9	-	-
	Simul. 16.9	4.82	8.52	0.967	0.389
12	Obs. 14	4	6	-	-
	Simul. 14.55	4.05	6.9	1	0.733

Tabla A.8: Percentiles de las longitudes de racha observada y simulada por *CM est*, Tortosa (1942-1981).

Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 3	1	1	-	-
	Simul. 3.21	1	1	0.991	0.327
2	Obs. 4	1	1	-	-
	Simul. 3.1	1.05	1.05	0.568	0.074
3	Obs. 3	2	1	-	-
	Simul. 3.05	1	1	0.018	0.001
4	Obs. 4	1	1	-	-
	Simul. 3.3	1	1.1	0.756	0.169
5	Obs. 3	1	1	-	-
	Simul. 3.1	1	1.05	0.769	0.218
6	Obs. 3	1	1	-	-
	Simul. 2.93	1	1	0.479	0.129
7	Obs. 2	1	1	-	-
	Simul. 2.27	1	0.8	0.556	0.097
8	Obs. 2	1	1	-	-
	Simul. 2.43	1	1	1	0.683
9	Obs. 3.2	1	1	-	-
	Simul. 3	1	1	0.164	0.017
10	Obs. 4	1	1	-	-
	Simul. 3.19	1	1	0.375	0.323
11	Obs. 3	1	1	-	-
	Simul. 2.9	1	1	0.33	0.051
12	Obs. 4	2	1	-	-
	Simul. 3.18	1	1	0.076	0.008

Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 16.1	3	6	-	-
	Simul. 15.75	3.95	7.11	0.811	0.469
2	Obs. 15	4	7	-	-
	Simul. 13.62	3.7	6.44	0.929	0.936
3	Obs. 14	4	7.5	-	-
	Simul. 12.78	3.4	5.65	0.915	0.735
4	Obs. 12	3	6	-	-
	Simul. 12.19	3.32	5.5	0.716	0.64
5	Obs. 11	3	6	-	-
	Simul. 10.79	2.95	4.92	0.785	0.518
6	Obs. 16	4	7	-	-
	Simul. 15.82	3.78	7.29	0.989	0.922
7	Obs. 19	6	8.5	-	-
	Simul. 18.83	5.75	8.81	0.425	0.24
8	Obs. 14	4	7	-	-
	Simul. 15.24	4.47	7.06	0.935	0.769
9	Obs. 14	5	7	-	-
	Simul. 12.52	3.45	5.69	0.012	0.022
10	Obs. 13.3	4	5.75	-	-
	Simul. 14.36	3.7	5.78	0.232	0.108
11	Obs. 19.6	6	9	-	-
	Simul. 16.16	4.92	7.64	0.816	0.447
12	Obs. 14	4	6	-	-
	Simul. 13.95	3.82	6.18	1	0.752

Tabla A.9: Percentiles de las longitudes de racha observada y simulada por *CM temp*, Tortosa (1942-1981).

AIC: 2920.11		BIC: 2962.28	
Estad. HL -		p-valor -	
% variabilidad explicada por modelo			12.19
Autocorrelación orden 1 en residuos			0.04
% días bien clasificados (0.5)		Anual	77.62
Primavera	Verano	Otoño	Invierno
73.53	83.02	75.82	78.21
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	85.05	50.15
	Húmedo	0	0
%NAS		Anual	0
Primavera	Verano	Otoño	Invierno
0	0	0	0
% días bien clasificados (frec. día)		Anual	72.25
Primavera	Verano	Otoño	Invierno
73.27	61.23	77.47	76.83
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	89.82	0
	Húmedo	12.81	100
%NAS		Anual	30.4
Primavera	Verano	Otoño	Invierno
32.8	18.08	39.26	34.75
Índice relativo de Brier		Anual	12.22
Primavera	Verano	Otoño	Invierno
10.15	3.2	16.84	14.93
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9685	Coef. eficiencia	0.575
Índice de acuerdo	0.7782	% medio error	1.440

Tabla A.10: Medidas de bondad de ajuste de *CM hom*, Tortosa periodo de validación (1982-1991).

AIC: 2940.57		BIC: 3091.16	
Estad. HL	16.71	p-valor	0.03
% variabilidad explicada por modelo			12.85
Autocorrelación orden 1 en residuos			0.04
% días bien clasificados (0.5)		Anual	77.56
Primavera	Verano	Otoño	Invierno
72.76	83.29	75.96	78.34
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	82.82
	Húmedo	0	16.67
%NAS		Anual	7.31
Primavera	Verano	Otoño	Invierno
13.41	2.34	5.41	4.44
% días bien clasificados (frec. día)		Anual	74.54
Primavera	Verano	Otoño	Invierno
72.38	73.26	77.2	75.44
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	93.44	0
	Húmedo	11.7	100
%NAS		Anual	32.02
Primavera	Verano	Otoño	Invierno
33.74	20.95	38.75	33.45
Índice relativo de Brier		Anual	12.87
Primavera	Verano	Otoño	Invierno
10.72	5.55	17.11	14.74
Días de precipitación observados y estimados por meses			
Coef. correlación	0.8663	Coef. eficiencia	0.6897
Índice de acuerdo	0.884	% medio error	0.1488

Tabla A.11: Medidas de bondad de ajuste de *CM est*, Tortosa periodo de validación (1982-1991).

AIC: 2642.24		BIC: 2810.9	
Estad. HL 24.34		p-valor 0	
% variabilidad explicada por modelo		23.32	
Autocorrelación orden 1 en residuos		0.05	
% días bien clasificados (0.5)		Anual	81.88
Primavera	Verano	Otoño	Invierno
80.05	84.22	81.32	81.99
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	99.76	84.97
	Húmedo	4.74	51.54
%NAS		Anual	24.97
Primavera	Verano	Otoño	Invierno
29.73	11.28	27.27	26.67
% días bien clasificados (frec. día)		Anual	73.92
Primavera	Verano	Otoño	Invierno
75.83	74.33	75.14	70.53
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	86.54	16.26
	Húmedo	35.93	94.44
%NAS		Anual	35.34
Primavera	Verano	Otoño	Invierno
42.73	25.87	39.06	32.17
Índice relativo de Brier		Anual	23.35
Primavera	Verano	Otoño	Invierno
27.46	15.18	25.38	21.26
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9036	Coef. eficiencia	0.7096
Índice de acuerdo	0.8987	% medio error	4.574

Tabla A.12: Medidas de bondad de ajuste para *CM temp*, Tortosa periodo de validación (1982-1991).

Rachas secas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor test $X^2$
1	5.18	3	5.21	5.75	0.536
2	5.49	4	5	6	0.275
3	6.72	3	7.76	8	0.531
4	5.79	3.5	6.48	7	0.841
5	3.71	2	3.78	3.5	0.092
6	5.81	3	7.29	5	0.361
7	10.39	9.5	9.92	11	0.762
8	6.47	5	5.53	7.75	0.814
9	6.93	4	6.88	5.25	0.43
10	6.44	5	5.07	9	0.765
11	7.28	4	6.89	8	0.242
12	10.04	4	13.49	8	0.727
Teórica	6.32	4	6.38	7	–
Rachas húmedas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor test $X^2$
1	2.07	2	1.74	1	0.069
2	2.03	2	1.24	2	0.546
3	1.74	1	1.12	1	0.962
4	1.79	1.5	1.05	1	0.14
5	2.08	2	1.42	2	0.663
6	1.51	1	0.79	1	0.497
7	1.33	1	0.76	0	0.119
8	1.57	1	0.73	1	0.182
9	1.9	1	1.4	1	0.984
10	2.1	1	1.95	1	0.345
11	2.73	2	1.93	2	0.014
12	1.68	1	1.31	1	0.582
Teórica	1.82	1	1.23	1	–

Tabla A.13: Distribuciones de las longitudes de racha observada y teórica según *CM hom*, por meses, Tortosa (1982-1991).

## Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	4.1	2	1	—
	Simul.	3.22	1.3	1.12	0.993
2	Obs.	3.4	2	2	—
	Simul.	3.26	1.3	1.15	0.753
3	Obs.	3	1	1	—
	Simul.	3.51	1.52	1.16	0.996
4	Obs.	3.9	1.5	1	—
	Simul.	3.4	1.38	1.11	0.997
5	Obs.	4.1	2	2	—
	Simul.	3.52	1.55	1.41	1
6	Obs.	3	1	1	—
	Simul.	2.68	1.05	0.98	1
7	Obs.	2	1	0	—
	Simul.	2.44	1	0.69	0.951
8	Obs.	2	1	1	—
	Simul.	2.49	1.1	0.95	0.846
9	Obs.	3.1	1	1	—
	Simul.	3.41	1.42	1.32	1
10	Obs.	4	1	1	—
	Simul.	3.61	1.5	1.51	1
11	Obs.	5.5	2	2	—
	Simul.	3.08	1.27	1.18	0.09
12	Obs.	3	1	1	—
	Simul.	3.67	1.52	1.31	0.452

## Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	13.6	3	6	—
	Simul.	14.79	4.25	6.99	0.668
2	Obs.	13	4	5	—
	Simul.	16.44	4.65	7.24	0.416
3	Obs.	12	4	5	—
	Simul.	14.89	4	6.76	0.967
4	Obs.	12.9	3.5	7	—
	Simul.	12.06	4.18	6	0.591
5	Obs.	7.3	2	3.75	—
	Simul.	10.88	2.88	4.88	0.779
6	Obs.	17	3	5	—
	Simul.	15.78	4.03	6.78	0.558
7	Obs.	25.6	10.5	14.5	—
	Simul.	18.3	6.58	8.46	0.165
8	Obs.	12.9	4.5	8	—
	Simul.	15.27	5.18	7.36	0.963
9	Obs.	20	4	5.25	—
	Simul.	12.67	4.15	6.21	0.904
10	Obs.	14	5	8	—
	Simul.	15.65	4.45	6.82	0.906
11	Obs.	12	4	8	—
	Simul.	16.66	5.45	8	0.795
12	Obs.	31.6	4	9.75	—
	Simul.	14.82	4.5	7.39	0.51

Tabla A.14: Percentiles de las longitudes de racha observada y simulada por *CM est*, Tortosa (1982-1991).

Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 4.1	2	1	-	-
	Simul. 3.1	1.05	0.99	0.621	0.191
2	Obs. 3.4	2	2	-	-
	Simul. 3.22	1.02	1.02	0.198	0.037
3	Obs. 3	1	1	-	-
	Simul. 2.93	1.08	1.05	1	0.743
4	Obs. 3.9	1.5	1	-	-
	Simul. 3.14	1.08	0.92	0.649	0.261
5	Obs. 4.1	2	2	-	-
	Simul. 3.02	1.2	1.05	0.92	0.175
6	Obs. 3	1	1	-	-
	Simul. 2.47	1	0.86	1	0.746
7	Obs. 2	1	0	-	-
	Simul. 1.9	1	0.24	1	0.791
8	Obs. 2	1	1	-	-
	Simul. 2.41	1	0.82	0.619	0.213
9	Obs. 3.1	1	1	-	-
	Simul. 2.48	1	0.95	0.856	0.154
10	Obs. 4	1	1	-	-
	Simul. 2.81	1.18	0.88	0.837	0.321
11	Obs. 5.5	2	2	-	-
	Simul. 3.03	1.2	0.96	0.031	0.001
12	Obs. 3	1	1	-	-
	Simul. 2.8	1.08	1	1	0.751

Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 13.6	3	6	-	-
	Simul. 16.22	4	7.48	0.823	0.355
2	Obs. 13	4	5	-	-
	Simul. 12.94	3.82	5.61	0.789	0.937
3	Obs. 12	4	5	-	-
	Simul. 14.92	4.32	6.49	0.994	0.7
4	Obs. 12.9	3.5	7	-	-
	Simul. 12.04	3.65	5.98	0.571	0.62
5	Obs. 7.3	2	3.75	-	-
	Simul. 11.01	3.18	4.39	0.498	0.166
6	Obs. 17	3	5	-	-
	Simul. 15.54	4.38	7.61	0.462	0.343
7	Obs. 25.6	10.5	14.5	-	-
	Simul. 20.94	7.5	10.14	0.624	0.446
8	Obs. 12.9	4.5	8	-	-
	Simul. 15.1	5.12	6.54	0.889	0.647
9	Obs. 20	4	5.25	-	-
	Simul. 13.88	4.72	7.14	0.921	0.881
10	Obs. 14	5	8	-	-
	Simul. 13.71	4.47	6.6	0.993	0.692
11	Obs. 12	4	8	-	-
	Simul. 14.33	4.85	7.45	0.533	0.49
12	Obs. 31.6	4	9.75	-	-
	Simul. 14.19	3.6	6.06	0.373	0.099

Tabla A.15: Percentiles de las longitudes de racha observada y simulada por *CM temp*, Tortosa (1982-1991).

### **A.1.2 Reinosa**

Cadena de Markov homogénea			
Término	Coef.	Error std.	Estadístico $t$
$\beta_0$	-1.332	0.03309	-40.240
$Y_{t-1}$	1.789	0.05011	35.700
$Y_{t-2}$	0.368	0.05234	7.030
$Y_{t-1} : Y_{t-2}$	-0.4561	0.07174	-6.357
$Y_{t-3}$	0.2263	0.03872	5.843
$Y_{t-4}$	0.1019	0.03892	2.619
$Y_{t-5}$	0.1183	0.03903	3.031
$Y_{t-6}$	0.0758	0.03674	2.063
Cadena de Markov estacional			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-1.150	0.02984	-38.530
$Y_{t-1}$	1.735	0.05055	34.320
$Y_{t-2}$	0.2997	0.05334	5.618
$Y_{t-1} : Y_{t-2}$	-0.4753	0.07269	-6.539
$Y_{t-3}$	0.180	0.03711	4.850
$S1$	0.1321	0.03298	4.006
$C1$	0.3013	0.03329	9.049
$S2$	-0.2537	0.0332	-7.640
$C2$	-0.03757	0.03291	-1.142
$S3$	0.08236	0.02461	3.346
$C3$	0.04282	0.02413	1.774
$S4$	-0.06276	0.02422	-2.592
$C4$	-0.0226	0.02405	-0.940
$S5$	0.06428	0.02406	2.671
$C5$	-0.02112	0.02402	-0.879
$S6$	-0.001886	0.024	-0.0786
$C6$	0.05483	0.02401	2.283
$Y_{t-2} : S1$	0.163	0.04843	3.366
$Y_{t-2} : C1$	0.1984	0.05051	3.927
$Y_{t-2} : S2$	0.03748	0.04964	0.755
$Y_{t-2} : C2$	-0.1227	0.04896	-2.505

Tabla A.16: Modelos markovianos homogéneo y estacional para el proceso de ocurrencia en Reinosá.

Cadena de Markov con información de temperatura			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-0.08402	0.1106	-0.760
$Y_{t-1}$	1.977	0.1685	11.740
$Y_{t-2}$	0.6658	0.1946	3.421
$Y_{t-1} : Y_{t-2}$	-0.4464	0.08364	-5.338
$Y_{t-3}$	0.1822	0.03943	4.620
$S1$	0.1627	0.0406	4.009
$C1$	0.2998	0.06105	4.911
$S2$	-0.2301	0.02773	-8.297
$C2$	-0.2018	0.02668	-7.564
$Y_{t-2} : S1$	-0.01445	0.06034	-0.240
$Y_{t-2} : C1$	-0.2378	0.08707	-2.731
$S3$	0.1156	0.02559	4.517
$C3$	0.03881	0.02529	1.534
$S4$	-0.07932	0.02542	-3.121
$C4$	-0.02149	0.02528	-0.850
$S5$	0.08216	0.02535	3.241
$C5$	-0.02068	0.02525	-0.819
$S6$	0.008384	0.02527	0.332
$C6$	0.05382	0.02527	2.129
$TDIF_t$	-0.01467	7.254e-4	-20.230
$Y_{t-1} : TDIF_t$	-0.01148	0.003257	-3.525
$Y_{t-1} : TDIF_t^2$	4.208e-5	1.667e-5	2.525
$Y_{t-2} : TDIF_t$	-0.007241	0.00122	-5.934
$TDIF_{t-1}$	0.004569	6.091e-4	7.502
$Y_{t-2} : TDIF_{t-1}$	0.01013	0.003	3.376
$Y_{t-2} : TDIF_{t-1}^2$	-3.216e-5	1.581e-5	-2.034
$TMIN_t$	5.287e-4	9.297e-4	0.569
$TMIN_t^2$	2.007e-5	5.309e-6	3.780
$Y_{t-1} : TMIN_t$	-0.002107	7.455e-4	-2.827
$Y_{t-2} : TMIN_t$	-0.005523	0.001274	-4.337

Tabla A.17: Modelo de cadena de Markov con información de temperatura ajustado en Reinoso.

		Deviance	Gr. lib.
Modelo nulo		23854.03	17399
Modelo ajustado		20844.96	17391
AIC:	20860.96	BIC:	20923.07
Estad. HL	3.50	p-valor	0.899
% variabilidad explicada por modelo			16.75
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	70.32
Primavera	Verano	Otoño	Invierno
68.54	72.84	70.12	69.74
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	0
	Húmedo	0	100
%NAS		Anual	49.41
Primavera	Verano	Otoño	Invierno
52.08	34.12	49.46	56.24
% días bien clasificados (frec. día)		Anual	64.33
Primavera	Verano	Otoño	Invierno
68.54	50.06	69.29	69.74
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	82.08	0
	Húmedo	9.57	100
%NAS		Anual	46.02
Primavera	Verano	Otoño	Invierno
52.08	27.63	49.28	56.24
Índice relativo de Brier		Anual	16.75
Primavera	Verano	Otoño	Invierno
14.06	5.98	16.05	15.27
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9984	Coef. eficiencia	0.7564
Índice de acuerdo	0.8928	% medio error	4.574
Días de precipitación observados y estimados por años			
Coef. correlación	0.9984	Coef. eficiencia	0.7606
Índice de acuerdo	0.8953	% medio error	0.6411

Tabla A.18: Medidas de bondad de ajuste de la cadena de Markov homogénea, Reinosa (1912-1959).

		Deviance	Gr. lib.
Modelo nulo		23862.93	— 17405
Modelo ajustado		20484.33	17384
AIC:	20526.33	BIC:	20689.39
Estad. HL	10.45	p-valor	0.24
% variabilidad explicada por modelo			18.57
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	70.64
Primavera	Verano	Otoño	Invierno
68.54	74.13	70.12	69.71
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	10.22
	Húmedo	0	95.9
%NAS		Anual	48.63
Primavera	Verano	Otoño	Invierno
52.08	26.61	49.46	56.21
% días bien clasificados (frec. día)		Anual	70.31
Primavera	Verano	Otoño	Invierno
68.54	72.84	70.12	69.71
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	0
	Húmedo	0	100
%NAS		Anual	49.4
Primavera	Verano	Otoño	Invierno
52.08	34.12	49.46	56.21
Índice relativo de Brier		Anual	18.57
Primavera	Verano	Otoño	Invierno
14.44	11.68	17.22	16.3
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9977	Coef. eficiencia	0.9953
Índice de acuerdo	0.9988	% medio error	0.047
Días de precipitación observados y estimados por años			
Coef. correlación	0.9765	Coef. eficiencia	0.6729
Índice de acuerdo	0.8422	% medio error	0.6894

Tabla A.19: Medidas de bondad de ajuste de la cadena de Markov estacional, Reinosa (1912-1959).

		Deviance	Gr. lib.
Modelo nulo		23857.33	17401
Modelo ajustado		18842.31	17371
AIC:	18902.31	BIC:	19135.23
Estad. HL	21.68	p-valor	0.01
% variabilidad explicada por modelo			26.5
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	73.19
Primavera	Verano	Otoño	Invierno
72.17	75.33	73.66	71.52
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	95.55	33.04
	Húmedo	18.7	89.75
%NAS		Anual	51.78
Primavera	Verano	Otoño	Invierno
56.5	28.07	53	58.53
% días bien clasificados (frec. día)		Anual	70.74
Primavera	Verano	Otoño	Invierno
72.05	67.33	72.49	71.14
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	88.01	23.82
	Húmedo	25.55	93.28
%NAS		Anual	51.31
Primavera	Verano	Otoño	Invierno
56.01	35.31	53.97	56.84
Índice relativo de Brier		Anual	26.5
Primavera	Verano	Otoño	Invierno
24.76	14.5	27.86	24.54
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9981	Coef. eficiencia	0.9962
Índice de acuerdo	0.999	% medio error	0.08015
Días de precipitación observados y estimados por años			
Coef. correlación	0.9206	Coef. eficiencia	0.6979
Índice de acuerdo	0.8675	% medio error	0.6326

Tabla A.20: Medidas de bondad de ajuste de la cadena de Markov con información de temperatura, Reinosa (1912-1959).

Longitud	Rachas secas		Rachas húmedas	
	Observada	Ajustada	Observada	Ajustada
1	0.34	0.34	0.342	0.342
2	0.187	0.185	0.251	0.25
3	0.12	0.117	0.142	0.138
4	0.086	0.085	0.083	0.088
5	0.059	0.061	0.058	0.056
6	0.045	0.044	0.036	0.037
7	0.031	0.035	0.026	0.026
8	0.03	0.028	0.018	0.018
9	0.019	0.022	0.012	0.013
10	0.017	0.017	0.01	0.009
11	0.01	0.014	0.008	0.007
12	0.011	0.011	0.006	0.005
13	0.011	0.009	0.002	0.003
14	0.011	0.007	0.001	0.002
15	0.005	0.005	0.002	0.002
16	0.004	0.004	0	0.001
17	0.003	0.003	0.002	0.001
18	0.001	0.003	0	0.001
19	0.003	0.002	0	0
$\geq 20$	0.009	0.001	0.002	0
p-valor test $X^2$	0.175		0.189	

Tabla A.21: Distribución de las longitudes de racha observada y teórica según *CM hom*, Reinosa (1912-1959).

Rachas secas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor test $X^2$
1	3.23	2	3.31	3	0.657
2	3.49	2	4.48	3	0.099
3	2.97	2	3.13	2	0.281
4	3.17	2	3.1	3	0.499
5	3.28	2	3.28	3	0.848
6	4.1	3	3.51	3.75	0.086
7	7.24	5	6.7	8	0
8	5.29	4	4.37	5	0
9	4.3	3	4.32	4.5	0.096
10	3.6	2.5	3.18	4	0.402
11	3.02	2	3.25	3	0.117
12	2.73	2	2.55	2	0.071
Teórica	3.78	2	3.85	4	—
Rachas húmedas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor test $X^2$
1	3.52	3	3.36	3	0.008
2	3.68	2	3.36	4	0.080
3	3.23	2	2.8	3	0.587
4	3.4	2	3.14	3	0.540
5	2.94	2	2.31	3	0.409
6	2.18	2	1.43	2	0.004
7	1.9	2	1.23	1	0
8	1.8	1	1.25	1	0
9	2.62	2	2.03	2	0.502
10	2.98	2	2.44	3	0.006
11	3.34	2	2.5	3.5	0.043
12	3.53	2	3.21	3.25	0.011
Teórica	2.95	2	2.59	3	—

Tabla A.22: Distribución de la longitud de racha, observada y teórica según *CM hom*, por meses, Reinosa (1912-1959).

## Rachas húmedas

Mes		$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	7	3	3	-	-
	Simul.	7.24	2.42	3.48	0.997	0.858
2	Obs.	8	2	4	-	-
	Simul.	7.51	2.05	3.48	0.85	0.318
3	Obs.	6.9	2	3	-	-
	Simul.	7.24	2.15	3.42	0.685	0.913
4	Obs.	7	2	3	-	-
	Simul.	7.36	2.3	3.61	0.972	0.493
5	Obs.	6	2	3	-	-
	Simul.	5.92	2.05	2.85	0.999	0.692
6	Obs.	4	2	2	-	-
	Simul.	4.48	2	2	0.533	0.097
7	Obs.	3	2	1	-	-
	Simul.	3.1	1.4	1.01	0.951	0.245
8	Obs.	3	1	1	-	-
	Simul.	3.68	1.78	1.25	0.013	0.01
9	Obs.	5	2	2	-	-
	Simul.	4.86	2	2.04	0.593	0.162
10	Obs.	6	2	3	-	-
	Simul.	5.9	2	2.72	0.982	0.71
11	Obs.	7	2	3.5	-	-
	Simul.	7.16	2.2	3.39	0.918	0.547
12	Obs.	7	2	3.25	-	-
	Simul.	7.56	2.45	3.52	1	0.773

## Rachas secas

Mes		$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	8	2	3	-	-
	Simul.	6.91	2	3.06	0.966	0.774
2	Obs.	9	2	3	-	-
	Simul.	7.46	2	3.15	0.743	0.438
3	Obs.	6	2	2	-	-
	Simul.	7.31	2	3.15	0.374	0.335
4	Obs.	7	2	3	-	-
	Simul.	6.94	2	3.15	1	0.916
5	Obs.	7	2	3	-	-
	Simul.	7.02	2.05	3.2	1	0.63
6	Obs.	8.7	3	3.75	-	-
	Simul.	10.01	3	4.29	0.96	0.856
7	Obs.	15	5	8	-	-
	Simul.	16.34	5.05	7.54	0.988	0.604
8	Obs.	11	4	5	-	-
	Simul.	11.86	3.88	5.54	0.835	0.878
9	Obs.	10	3	4.5	-	-
	Simul.	9.45	2.92	4.64	0.93	0.791
10	Obs.	8	2.5	4	-	-
	Simul.	7.53	2.2	3.5	0.864	0.268
11	Obs.	6	2	3	-	-
	Simul.	6.17	2	2.95	0.996	0.848
12	Obs.	5.8	2	2	-	-
	Simul.	6.31	2	2.85	0.809	0.462

Tabla A.23: Percentiles de las longitudes de racha observada y simulada por *CM est*, Reinosá (1912-1959).

Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 7	3	3	-	-
	Simul. 6.35	2.05	2.98	0.208	0.101
2	Obs. 8	2	4	-	-
	Simul. 6.18	2	2.78	0.115	0.002
3	Obs. 6.9	2	3	-	-
	Simul. 5.86	2	2.8	0.199	0.028
4	Obs. 7	2	3	-	-
	Simul. 5.62	2	2.4	0.028	0.006
5	Obs. 6	2	3	-	-
	Simul. 5.05	2	2	0.046	0.001
6	Obs. 4	2	2	-	-
	Simul. 3.76	1.8	1.25	0.049	0.008
7	Obs. 3	2	1	-	-
	Simul. 2.61	1	1	0	0
8	Obs. 3	1	1	-	-
	Simul. 2.94	1	1	0.221	0.299
9	Obs. 5	2	2	-	-
	Simul. 3.8	1.85	1.23	0.005	0
10	Obs. 6	2	3	-	-
	Simul. 4.83	2	2.05	0.036	0
11	Obs. 7	2	3.5	-	-
	Simul. 6.35	2	2.98	0.295	0.02
12	Obs. 7	2	3.25	-	-
	Simul. 6.76	2.02	3.05	0.727	0.113

Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 8	2	3	-	-
	Simul. 5.84	1.95	2.6	0.358	0.107
2	Obs. 9	2	3	-	-
	Simul. 6.35	2	2.69	0.472	0.638
3	Obs. 6	2	2	-	-
	Simul. 5.98	2	2.58	1	0.609
4	Obs. 7	2	3	-	-
	Simul. 5.58	1.95	2.19	0.124	0.017
5	Obs. 7	2	3	-	-
	Simul. 5.96	2	2.71	0.526	0.038
6	Obs. 8.7	3	3.75	-	-
	Simul. 8.29	2.17	3.78	0.002	0.002
7	Obs. 15	5	8	-	-
	Simul. 14.63	4.45	6.85	0.387	0.067
8	Obs. 11	4	5	-	-
	Simul. 10.52	3.3	4.66	0.029	0.015
9	Obs. 10	3	4.5	-	-
	Simul. 7.8	2.35	3.59	0.188	0.062
10	Obs. 8	2.5	4	-	-
	Simul. 6.68	2	3.02	0.231	0.032
11	Obs. 6	2	3	-	-
	Simul. 5.28	1.88	2.05	0.126	0.036
12	Obs. 5.8	2	2	-	-
	Simul. 5.39	1.85	2.2	0.379	0.153

Tabla A.24: Percentiles de las longitudes de racha observada y simulada por *CM temp*, Reinoso (1912-1959).

AIC: 6752.84		BIC: 6806	
Estad. HL 11.54		p-valor 0.17	
% variabilidad explicada por modelo		17.55	
Autocorrelación orden 1 en residuos		-0.01	
% días bien clasificados (0.5)		Anual	70.45
Primavera	Verano	Otoño	Invierno
66.51	75.18	71.65	68.58
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	0
	Húmedo	0	100
%NAS		Anual	49.07
Primavera	Verano	Otoño	Invierno
50.65	30.45	51.12	55.44
% días bien clasificados (frec. día)		Anual	64.87
Primavera	Verano	Otoño	Invierno
66.51	53.86	70.72	68.58
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	83.94	0
	Húmedo	7.87	100
%NAS		Anual	45.76
Primavera	Verano	Otoño	Invierno
50.65	24.63	50.67	55.44
Índice relativo de Brier		Anual	17.56
Primavera	Verano	Otoño	Invierno
10.58	3.04	19.38	13.83
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9972	Coef. eficiencia	0.7624
Índice de acuerdo	0.8965	% medio error	8.312

Tabla A.25: Medidas de bondad de ajuste de *CM hom*, Reinos, periodo de validación (1960-1975).

AIC: 6686.4		BIC: 6825.97	
Estad. HL 8.36		p-valor 0.4	
% variabilidad explicada por modelo			19.05
Autocorrelación orden 1 en residuos			-0.02
% días bien clasificados (0.5)		Anual	70.78
Primavera	Verano	Otoño	Invierno
66.51	76.56	71.57	68.58
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	9.03
	Húmedo	0	96.54
%NAS		Anual	48.47
Primavera	Verano	Otoño	Invierno
50.65	22.81	51.05	55.44
% días bien clasificados (frec. día)		Anual	70.43
Primavera	Verano	Otoño	Invierno
66.51	75.16	71.57	68.58
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	0
	Húmedo	0	100
%NAS		Anual	49.05
Primavera	Verano	Otoño	Invierno
50.65	30.39	51.05	55.44
Índice relativo de Brier		Anual	19.06
Primavera	Verano	Otoño	Invierno
10.81	9.39	19.68	14.57
Días de precipitación observados y estimados por meses			
Coef. correlación	0.994	Coef. eficiencia	0.9776
Índice de acuerdo	0.9938	% medio error	2.940

Tabla A.26: Medidas de bondad de ajuste de *CM est*, Reinosá, periodo de validación (1960-1975).

AIC: 6080.33		BIC: 6279.7	
Estad. HL	20.43	p-valor	0.01
% variabilidad explicada por modelo			28.45
Autocorrelación orden 1 en residuos			-0.02
% días bien clasificados (0.5)		Anual	73.98
Primavera	Verano	Otoño	Invierno
70.65	78.29	75.16	71.91
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	94.89	32.54
	Húmedo	22.38	91.53
%NAS		Anual	53
Primavera	Verano	Otoño	Invierno
56.01	27.23	55.35	59.44
% días bien clasificados (frec. día)		Anual	70.99
Primavera	Verano	Otoño	Invierno
70.79	66.39	74.52	72.41
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	87.22	23.87
	Húmedo	28.21	93.82
%NAS		Anual	51.54
Primavera	Verano	Otoño	Invierno
55.85	28.99	56.55	58.97
Índice relativo de Brier		Anual	28.46
Primavera	Verano	Otoño	Invierno
23.86	10.78	31.28	26.16
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9967	Coef. eficiencia	0.9734
Índice de acuerdo	0.9927	% medio error	5.193

Tabla A.27: Medidas de bondad de ajuste de *CM temp*, Reínoša, periodo de validación (1960-1975).

Rachas secas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor test $X^2$
1	3.01	2	3	3	0.652
2	2.91	2	3.23	2	0.462
3	2.91	2	2.49	3	0.151
4	2.65	2	2.86	2	0.141
5	3.18	2	3.11	3	0.867
6	5.75	3	6.31	6	0.037
7	7.59	5	6.37	8.5	0
8	6.9	5	8.13	6.5	0.003
9	4.43	3	4.25	5	0.093
10	4.16	2	4.26	5	0.987
11	2.82	1	3.07	3	0.104
12	2.8	2	2.52	3	0.101
Teórica	3.78	2	3.85	4	—
Rachas húmedas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor test $X^2$
1	3.05	2	2.48	2.5	0.527
2	3.27	2	2.93	3	0.825
3	3.28	3	2.18	3	0.086
4	3.11	2	2.51	3	0.769
5	2.74	2	2.44	2	0.956
6	2.02	2	1.36	1	0.102
7	1.58	1	1.07	1	0
8	1.95	2	1.01	2	0.068
9	2.66	2	2.12	2	0.944
10	3.19	2	3.34	2	0.372
11	3.67	3	3.03	2.5	0.085
12	3.87	2	4.12	4	0.659
Teórica	2.95	2	2.59	3	—

Tabla A.28: Distribuciones de las longitudes de racha observada y teórica según *CM hom*, por meses, Reinosa (1960-1975).

## Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 7	2	2.5	-	-
	Simul. 7.15	2.35	3.2	0.667	0.495
2	Obs. 7	2	3	-	-
	Simul. 6.7	2.2	3.24	1	0.717
3	Obs. 6.2	3	3	-	-
	Simul. 7.28	2.12	3.46	0.21	0.162
4	Obs. 6.6	2	3	-	-
	Simul. 6.96	2.25	3.36	1	0.606
5	Obs. 5.9	2	2	-	-
	Simul. 5.69	2	2.58	0.984	0.342
6	Obs. 4	2	1	-	-
	Simul. 4.43	2.02	2.11	0.231	0.035
7	Obs. 2	1	1	-	-
	Simul. 3.12	1.52	1.1	0.275	0.04
8	Obs. 3.2	2	2	-	-
	Simul. 3.71	1.8	1.36	0.974	0.665
9	Obs. 5	2	2	-	-
	Simul. 4.81	1.98	1.95	1	0.606
10	Obs. 7	2	2	-	-
	Simul. 6.02	2.05	2.82	0.924	0.853
11	Obs. 8	3	2.5	-	-
	Simul. 7.32	2.35	2.98	0.776	0.398
12	Obs. 7	2	4	-	-
	Simul. 7.28	2.55	2.9	0.999	0.81

## Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 6	2	3	-	-
	Simul. 6.95	1.95	2.98	1	0.797
2	Obs. 6	2	2	-	-
	Simul. 7.24	2.1	3.16	0.492	0.452
3	Obs. 5.6	2	3	-	-
	Simul. 7.37	1.92	3.19	0.374	0.776
4	Obs. 5.3	2	2	-	-
	Simul. 6.22	1.98	2.56	0.818	0.173
5	Obs. 7	2	3	-	-
	Simul. 7.22	2.17	3.14	0.999	0.53
6	Obs. 14	3	6	-	-
	Simul. 10	2.78	4.69	0.363	0.241
7	Obs. 18	5	8.5	-	-
	Simul. 16.57	5.05	7.75	0.961	0.606
8	Obs. 13.2	5	6.5	-	-
	Simul. 12.43	4.32	6.08	0.982	0.649
9	Obs. 9.5	3	5	-	-
	Simul. 10.44	3.02	4.59	1	0.77
10	Obs. 9.8	2	5	-	-
	Simul. 7.32	2.25	3.58	0.333	0.482
11	Obs. 5.3	1	3	-	-
	Simul. 6.18	2	2.66	0.321	0.197
12	Obs. 6	2	3	-	-
	Simul. 6.24	1.98	2.79	0.855	0.456

Tabla A.29: Percentiles de las longitudes de racha observada y simulada por *CM est*, Reinosá (1960-1975).

Rachas húmedas

Mes		$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	7	2	2.5	-	-
	Simul.	6.14	2.08	2.86	0.996	0.887
2	Obs.	7	2	3	-	-
	Simul.	6.18	2.08	2.49	0.927	0.357
3	Obs.	6.2	3	3	-	-
	Simul.	6.35	2.25	3	0.293	0.109
4	Obs.	6.6	2	3	-	-
	Simul.	5.84	2	2.71	0.703	0.333
5	Obs.	5.9	2	2	-	-
	Simul.	5.01	2	2.11	0.973	0.567
6	Obs.	4	2	1	-	-
	Simul.	3.62	1.52	1.36	1	0.728
7	Obs.	2	1	1	-	-
	Simul.	2.29	1	1	1	0.655
8	Obs.	3.2	2	2	-	-
	Simul.	3.09	1.02	1	0.149	0.014
9	Obs.	5	2	2	-	-
	Simul.	3.88	1.68	1.4	0.236	0.01
10	Obs.	7	2	2	-	-
	Simul.	5.01	2	2.2	0.531	0.124
11	Obs.	8	3	2.5	-	-
	Simul.	6.48	2.25	3	0.217	0.068
12	Obs.	7	2	4	-	-
	Simul.	6.59	2.12	3.01	0.965	0.253

Rachas secas

Mes		$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	6	2	3	-	-
	Simul.	5.2	1.72	2.08	0.881	0.185
2	Obs.	6	2	2	-	-
	Simul.	5.52	1.8	2.3	0.945	0.442
3	Obs.	5.6	2	3	-	-
	Simul.	5.32	1.85	2.35	0.021	0.017
4	Obs.	5.3	2	2	-	-
	Simul.	5.4	1.8	2.24	1	0.74
5	Obs.	7	2	3	-	-
	Simul.	5.82	1.95	2.48	0.969	0.313
6	Obs.	14	3	6	-	-
	Simul.	8.51	2.35	4	0.135	0.053
7	Obs.	18	5	8.5	-	-
	Simul.	14.11	4.4	6.94	0.39	0.125
8	Obs.	13.2	5	6.5	-	-
	Simul.	9.56	3.22	4.35	0.062	0.014
9	Obs.	9.5	3	5	-	-
	Simul.	7.52	2.25	3.59	0.535	0.186
10	Obs.	9.8	2	5	-	-
	Simul.	6.73	2.08	2.99	0.126	0.141
11	Obs.	5.3	1	3	-	-
	Simul.	5.12	1.75	2.15	0.934	0.826
12	Obs.	6	2	3	-	-
	Simul.	5.2	1.58	2.16	0.512	0.5

Tabla A.30: Percentiles de las longitudes de racha observada y simulada por *CM temp*, Reinosá (1960-1975).

AIC: 4122.14		BIC: 4171.07	
Estad. HL 10.65		p-valor 0.22	
% variabilidad explicada por modelo			14.8
Autocorrelación orden 1 en residuos			-0.03
% días bien clasificados (0.5)		Anual	68.86
Primavera	Verano	Otoño	Invierno
68.88	68.63	68.57	69.41
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	0
	Húmedo	0	100
%NAS		Anual	49.29
Primavera	Verano	Otoño	Invierno
55.43	33.73	48.56	55.93
% días bien clasificados (frec. día)		Anual	63.63
Primavera	Verano	Otoño	Invierno
68.88	49.6	67.8	69.41
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	81.49	0
	Húmedo	12.28	100
%NAS		Anual	46.95
Primavera	Verano	Otoño	Invierno
55.43	31.01	48.42	55.93
Índice relativo de Brier		Anual	14.82
Primavera	Verano	Otoño	Invierno
13.66	4.55	13.45	15.28
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9973	Coef. eficiencia	0.7431
Índice de acuerdo	0.8868	% medio error	1.451

Tabla A.31: Medidas de bondad de ajuste de *CM hom*, Reinosá (1985-1994).

AIC: 4098.83		BIC: 4227.3	
Estad. HL 11.96		p-valor 0.15	
% variabilidad explicada por modelo		16.4	
Autocorrelación orden 1 en residuos		-0.02	
% días bien clasificados (0.5)		Anual 69.51	
Primavera	Verano	Otoño	Invierno
69	70.99	68.57	69.41
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	12.64
	Húmedo	0	95.67
%NAS		Anual 48.77	
Primavera	Verano	Otoño	Invierno
55.68	27.61	48.56	55.93
% días bien clasificados (frec. día)		Anual 68.85	
Primavera	Verano	Otoño	Invierno
69	68.51	68.57	69.41
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	0
	Húmedo	0	100
%NAS		Anual 49.34	
Primavera	Verano	Otoño	Invierno
55.68	33.73	48.56	55.93
Índice relativo de Brier		Anual 16.42	
Primavera	Verano	Otoño	Invierno
14.7	9.04	13.79	16.32
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9595	Coef. eficiencia	0.9076
Índice de acuerdo	0.9758	% medio error	2.921

Tabla A.32: Medidas de bondad de ajuste de *CM est*, Reinosá (1985-1994).

AIC:		3778.04	BIC:		3961.53
Estad. HL		4.74	p-valor		0.78
% variabilidad explicada por modelo					24.83
Autocorrelación orden 1 en residuos					0
% días bien clasificados (0.5)			Anual	72.46	
Primavera	Verano		Otoño	Invierno	
72.03	74.01		71.4	72.36	
Día $t - 1$			Seco	Húmedo	
Día $t$	Seco		94.73	33.91	
	Húmedo		21.69	90.05	
%NAS			Anual	52.69	
Primavera	Verano		Otoño	Invierno	
59.65	30.72		51.85	60.11	
% días bien clasificados (frec. día)			Anual	69.68	
Primavera	Verano		Otoño	Invierno	
71.89	64.63		70.19	72.6	
Día $t - 1$			Seco	Húmedo	
Día $t$	Seco		85.04	22.03	
	Húmedo		31.29	94.38	
%NAS			Anual	52.48	
Primavera	Verano		Otoño	Invierno	
58.97	37.52		53.36	59.23	
Índice relativo de Brier			Anual	24.85	
Primavera	Verano		Otoño	Invierno	
23.35	16.28		24.5	24.39	
Días de precipitación observados y estimados por meses					
Coef. correlación	0.9596		Coef. eficiencia	0.9204	
Índice de acuerdo	0.9791		% medio error	0.6009	

Tabla A.33: Medidas de bondad de ajuste de *CM temp*, Reinos (1985-1994).

### **A.1.3 Agoncillo**

Cadena de Markov homogénea			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-1.601	0.05129	-31.220
$Y_{t-1}$	1.697	0.08708	19.490
$Y_{t-2}$	0.4896	0.0968	5.058
$Y_{t-1} : Y_{t-2}$	-0.7055	0.1369	-5.154
$Y_{t-3}$	0.2223	0.07343	3.028
$Y_{t-4}$	0.161	0.07085	2.272
Cadena de Markov con armónicos			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-1.531	0.0495	-30.930
$Y_{t-1}$	1.647	0.08773	18.770
$Y_{t-2}$	0.435	0.09748	4.463
$Y_{t-1} : Y_{t-2}$	-0.7075	0.1378	-5.135
$Y_{t-3}$	0.1936	0.07112	2.722
$S1$	0.2736	0.0453	6.040
$C1$	0.2258	0.04599	4.909
$S2$	-0.2431	0.0457	-5.319
$C2$	-0.09247	0.04483	-2.062
Cadena de Markov con temperaturas			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-0.981	0.2388	-4.108
$Y_{t-1}$	1.684	0.1413	11.920
$Y_{t-2}$	0.4434	0.1021	4.343
$Y_{t-1} : Y_{t-2}$	-0.5601	0.143	-3.917
$S1$	0.338	0.0602	5.614
$C1$	0.1435	0.09118	1.574
$S2$	-0.2175	0.05002	-4.348
$C2$	-0.1473	0.04739	-3.109
$TDIF_t$	-0.0174	0.001012	-17.190
$TDIF_{t-1}$	0.008871	0.001091	8.129
$TDIF_{t-2}$	0.003828	0.003279	1.167
$TDIF_{t-2}^2$	-3.270e-5	1.433e-5	-2.282
$TMIN_{t-1}$	0.005049	0.001254	4.026
$Y_{t-1} : TMIN_{t-1}$	-0.004394	0.001293	-3.400

Tabla A.34: Modelos markovianos homogéneo, estacional y con información de temperatura para el proceso de ocurrencia en Agoncillo.

Cadena de Markov con información de presión			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-1.500	0.06355	-23.610
$Y_{t-1}$	1.289	0.1034	12.470
$Y_{t-2}$	0.2663	0.1086	2.451
$Y_{t-1} : Y_{t-2}$	-0.4907	0.153	-3.207
$S1$	0.3003	0.05012	5.993
$C1$	0.3034	0.05321	5.702
$S2$	-0.3388	0.05065	-6.689
$C2$	-0.07222	0.04986	-1.448
$z.P07_t$	-0.02608	0.002664	-9.789
$z.P07_t^2$	-8.319e-5	1.152e-5	-7.220
$z.\Delta P.7.0_t$	-0.01421	0.003905	-3.638
$z.P18_t$	0.00512	0.001375	3.725
$Y_{t-1} : z.P18_t$	0.003653	0.001117	3.271
$z.P18_t^2$	3.740e-5	8.709e-6	4.295
$z.\Delta P.18.13_t$	-0.00126	4.081e-3	-0.309
$z.\Delta P.18.13_t^2$	4.461e-4	7.635e-5	5.843
$z.P18_{t-1}$	0.006799	0.002486	2.734
$z.P18_{t-1}^2$	1.768e-5	7.285e-6	2.427
$z.\Delta P.18.13_{t-1}$	-0.005976	0.002192	-2.726
Cadena de Markov con información de presión y temperatura			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-0.2479	0.1824	-1.359
$Y_{t-1}$	2.113	0.3443	6.136
$Y_{t-2}$	0.2792	0.1132	2.467
$Y_{t-1} : Y_{t-2}$	-0.4307	0.1578	-2.730
$S1$	0.2495	0.05206	4.793
$C1$	-0.04028	0.07048	-0.5716
$S2$	-0.2434	0.05332	-4.565
$C2$	-0.1442	0.05184	-2.781
$z.P07_t$	-0.007895	0.003294	-2.397
$z.P07_t^2$	-4.693e-5	7.383e-6	-6.356
$Y_{t-1} : z.P07_t^2$	2.278e-5	9.335e-6	2.440
$z.P18_t$	-0.01665	0.002685	-6.201
$Y_{t-1} : z.P18_t$	0.005558	0.001356	4.098
$z.\Delta P.18.13_t$	0.01674	0.004294	3.899
$z.\Delta P.18.13_t^2$	4.936e-4	7.807e-5	6.322
$z.P18_{t-1}$	0.009382	0.001317	7.123
$TDIF_t$	-0.01738	0.001449	-12.000
$Y_{t-1} : TDIF_t$	-0.02246	0.007207	-3.116
$Y_{t-1} : TDIF_t^2$	1.048e-4	3.840e-5	2.729
$TDIF_{t-1}$	0.005772	0.001103	5.233

Tabla A.35: Modelos de cadena de Markov con información de presión ajustados en Agoncillo.

		Deviance	Gr. lib.
Modelo nulo		6636.2	5426
Modelo ajustado		6000.14	5420
AIC:	6012.14	BIC:	6051.74
Estad. HL	–	p-valor	–
% variabilidad explicada por modelo			12.01
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	72.19
Primavera	Verano	Otoño	Invierno
68.39	79.13	72.34	68.74
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	20.08
	Húmedo	0	84.14
%NAS		Anual	32.66
Primavera	Verano	Otoño	Invierno
37.66	26.15	30.21	33.33
% días bien clasificados (frec. día)		Anual	63.4
Primavera	Verano	Otoño	Invierno
67.95	48.19	67.73	70.07
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	81.37	0
	Húmedo	13.52	100
%NAS		Anual	32.88
Primavera	Verano	Otoño	Invierno
41.33	21.08	32.29	40.06
Índice relativo de Brier		Anual	12.02
Primavera	Verano	Otoño	Invierno
11.05	6.42	10.43	11.1
Días de precipitación observados y estimados por meses			
Coef. correlación	0.996	Coef. eficiencia	0.6601
Índice de acuerdo	0.8312	% medio error	5.782
Días de precipitación observados y estimados por años			
Coef. correlación	0.9884	Coef. eficiencia	0.6493
Índice de acuerdo	0.8242	% medio error	0.6604

Tabla A.36: Medidas de bondad de ajuste de la cadena de Markov homogénea, Agoncillo (1978-1992).

		Deviance	Gr. lib.
Modelo nulo		6639.78	5431
Modelo ajustado		5926.99	5422
AIC:	5944.99	BIC:	6004.39
Estad. HL	3.39	p-valor	0.91
% variabilidad explicada por modelo			13.35
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	72.91
Primavera	Verano	Otoño	Invierno
67.7	80.22	74.16	69.43
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	33.16
	Húmedo	0	77.13
%NAS		Anual	31.33
Primavera	Verano	Otoño	Invierno
40.22	9	27.8	34.34
% días bien clasificados (frec. día)		Anual	70.85
Primavera	Verano	Otoño	Invierno
67.26	75.07	71.71	69.28
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	96.84	0
	Húmedo	4.99	100
%NAS		Anual	36.45
Primavera	Verano	Otoño	Invierno
42.17	26.81	33.97	38.79
Índice relativo de Brier		Anual	13.36
Primavera	Verano	Otoño	Invierno
11.95	10.21	11.65	11.38
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9795	Coef. eficiencia	0.9592
Índice de acuerdo	0.9893	% medio error	0.3103
Días de precipitación observados y estimados por años			
Coef. correlación	0.9881	Coef. eficiencia	0.5889
Índice de acuerdo	0.7785	% medio error	0.7155

Tabla A.37: Medidas de bondad de ajuste de la cadena de Markov estacional, Agoncillo (1978-1992).

		Deviance	Gr. lib.
Modelo nulo		6645.04	5436
Modelo ajustado		5593.31	5422
AIC:	5621.31	BIC:	5713.72
Estad. HL	14.44	p-valor	0.07
% variabilidad explicada por modelo			18.91
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	75.35
Primavera	Verano	Otoño	Invierno
70.7	81.81	77.46	71.3
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	99.11	51.63
	Húmedo	5.77	74.25
%NAS		Anual	33.99
Primavera	Verano	Otoño	Invierno
41.53	17.97	33.19	34.24
% días bien clasificados (frec. día)		Anual	68.25
Primavera	Verano	Otoño	Invierno
65.9	67.46	70.94	68.71
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	84.04	10.07
	Húmedo	31.45	96.55
%NAS		Anual	38.49
Primavera	Verano	Otoño	Invierno
43.86	26.99	39.6	41.17
Índice relativo de Brier		Anual	18.92
Primavera	Verano	Otoño	Invierno
17.53	11.95	20.79	16.95
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9787	Coef. eficiencia	0.9578
Índice de acuerdo	0.989	% medio error	0.2821
Días de precipitación observados y estimados por años			
Coef. correlación	0.6918	Coef. eficiencia	0.4783
Índice de acuerdo	0.8042	% medio error	0.6218

Tabla A.38: Medidas de bondad de ajuste de la cadena de Markov con información de temperatura, Agoncillo (1978-1992).

		Deviance	Gr. lib.
Modelo nulo		6634.77	5424
Modelo ajustado		4954.38	5406
AIC:	4990.38	BIC:	5109.16
Estad. HL	8.61	p-valor	0.38
% variabilidad explicada por modelo			29.33
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	78.37
Primavera	Verano	Otoño	Invierno
75.72	82.32	79.9	75.52
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	96.2	61.26
	Húmedo	29.66	74.02
%NAS		Anual	42.58
Primavera	Verano	Otoño	Invierno
50.3	21.94	42.22	45.02
% días bien clasificados (frec. día)		Anual	74.43
Primavera	Verano	Otoño	Invierno
72.84	73.48	76.85	74.56
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	86.03	26.83
	Húmedo	55.91	92.07
%NAS		Anual	46.94
Primavera	Verano	Otoño	Invierno
52.15	34.71	47.91	50.14
Índice relativo de Brier		Anual	29.34
Primavera	Verano	Otoño	Invierno
30.34	19.63	32.23	26.83
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9689	Coef. eficiencia	0.9386
Índice de acuerdo	0.9841	% medio error	0.2624
Días de precipitación observados y estimados por años			
Coef. correlación	0.7741	Coef. eficiencia	0.5698
Índice de acuerdo	0.8247	% medio error	0.6418

Tabla A.39: Medidas de bondad de ajuste de la cadena de Markov con presiones atmosféricas, Agoncillo (1978-1992).

		Deviance	Gr. lib.
Modelo nulo		6635.49	5425
Modelo ajustado		4767.96	5405
AIC:	4807.96	BIC:	4939.94
Estad. HL	16.76	p-valor	0.03
% variabilidad explicada por modelo			32.4
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	79.47
Primavera	Verano	Otoño	Invierno
77.05	82.32	81.1	77.37
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	95.51	66.49
	Húmedo	34.65	74.25
%NAS		Anual	44.96
Primavera	Verano	Otoño	Invierno
51.63	24.14	45.04	48.83
% días bien clasificados (frec. día)		Anual	75.04
Primavera	Verano	Otoño	Invierno
74.24	72.61	78.06	75.3
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	84.58	32.85
	Húmedo	59.97	92.07
%NAS		Anual	48.16
Primavera	Verano	Otoño	Invierno
54.56	33.86	49.75	51.45
Índice relativo de Brier		Anual	32.41
Primavera	Verano	Otoño	Invierno
33.3	20.79	35.94	31.03
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9758	Coef. eficiencia	0.9521
Índice de acuerdo	0.9877	% medio error	0.225
Días de precipitación observados y estimados por años			
Coef. correlación	0.7097	Coef. eficiencia	0.5003
Índice de acuerdo	0.8277	% medio error	0.5641

Tabla A.40: Medidas de bondad de ajuste de la cadena de Markov con temperaturas y presiones atmosféricas, Agoncillo (1978-1992).

Longitud	Rachas secas		Rachas húmedas	
	Observada	Ajustada	Observada	Ajustada
1	0.284	0.284	0.45	0.448
2	0.16	0.154	0.285	0.286
3	0.112	0.107	0.125	0.126
4	0.077	0.076	0.063	0.061
5	0.077	0.063	0.022	0.034
6	0.04	0.053	0.031	0.019
7	0.045	0.044	0.008	0.011
8	0.03	0.037	0.009	0.006
9	0.026	0.03	0.003	0.004
10	0.022	0.025	0.004	0.002
11	0.022	0.021	0	0.001
12	0.016	0.018	0	0.001
13	0.019	0.015	0	0
14	0.006	0.012	0	0
15	0.012	0.01	0	0
16	0.006	0.008	0	0
17	0.006	0.007	0	0
18	0.005	0.006	0	0
19	0.004	0.005	0	0
$\geq 20$	0.03	0.003	0	0
p-valor test $X^2$	0.307		0.027	

Tabla A.41: Distribuciones de las longitudes de racha observada y teórica según *CM hom*, Agoncillo (1978-1992).

Rachas secas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor
1	3.68	2	3.81	4	0.367
2	4.9	3	5.39	6	0.174
3	4	3	3.34	4	0.035
4	3.88	2	3.95	4	0.693
5	3.73	2	4.3	4	0.524
6	6.17	4	6.13	6	0.723
7	7.33	5	7.77	7	0.628
8	8.76	5.5	10.74	6	0.06
9	5.75	4	4.87	6	0.225
10	5.13	3	5.91	6	0.817
11	4.06	3	3.78	4	0.345
12	5.5	2.5	7.56	5	0.538
Teórica	4.96	3	5.1	6	—
Rachas húmedas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor
1	2.24	2	1.75	1	0.126
2	2.45	2	1.51	2	0.07
3	2.28	2	1.66	2	0.137
4	2.62	2	1.92	2	0.095
5	2.35	2	1.73	2	0.223
6	1.96	2	1.47	1	0.565
7	1.62	1	0.99	1	0.104
8	1.47	1	0.71	1	0.031
9	1.67	1	0.87	1	0.182
10	1.95	1.5	1.42	1	0.915
11	2.61	2	2	3	0.005
12	1.97	2	1.18	2	0.501
Teórica	2.14	2	1.58	2	—

Tabla A.42: Distribuciones de las longitudes de racha, observada y teórica según *CM hom*, por meses, Agoncillo (1978-1992).

Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 5	2	1	-	-
	Simul. 3.92	1.9	1.7	0.685	0.722
2	Obs. 4	2	2	-	-
	Simul. 4.01	1.8	1.8	0.324	0.078
3	Obs. 5.2	2	2	-	-
	Simul. 4.4	2	2.05	0.855	0.674
4	Obs. 5.2	2	2	-	-
	Simul. 4.89	2	2.21	0.996	0.813
5	Obs. 4	2	2	-	-
	Simul. 4.46	1.95	2.01	1	0.802
6	Obs. 3.6	2	1	-	-
	Simul. 3.64	1.75	1.3	1	0.763
7	Obs. 2.1	1	1	-	-
	Simul. 2.65	1.1	0.99	1	0.977
8	Obs. 2	1	1	-	-
	Simul. 2.6	1.05	0.99	1	0.739
9	Obs. 3	1	1	-	-
	Simul. 2.9	1.3	1.25	1	0.835
10	Obs. 3.5	1.5	1	-	-
	Simul. 3.87	1.7	1.6	1	0.546
11	Obs. 6	2	3	-	-
	Simul. 4.4	1.88	1.69	0.268	0.345
12	Obs. 3	2	2	-	-
	Simul. 4.14	1.95	1.94	0.934	0.279

Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 9	2	4	-	-
	Simul. 9.38	3	4.49	0.13	0.058
2	Obs. 11	3	6	-	-
	Simul. 10.27	3.18	4.92	1	0.918
3	Obs. 9.3	3	4	-	-
	Simul. 8.56	2.72	4.05	0.978	0.535
4	Obs. 10.8	2	4	-	-
	Simul. 7.61	2.28	3.51	0.961	0.597
5	Obs. 9.2	2	4	-	-
	Simul. 8.38	2.62	4.25	0.316	0.167
6	Obs. 14	4	6	-	-
	Simul. 13.01	3.95	6.12	0.996	0.726
7	Obs. 19	5	7	-	-
	Simul. 18.35	5.25	8.35	0.747	0.499
8	Obs. 21	5.5	6	-	-
	Simul. 17.5	6.12	8.54	0.641	0.897
9	Obs. 12.4	4	6	-	-
	Simul. 14.97	4.95	7.71	0.657	0.458
10	Obs. 12	3	6	-	-
	Simul. 11	3.38	5.4	0.713	0.472
11	Obs. 8.9	3	4	-	-
	Simul. 9.07	2.88	4.5	0.999	0.798
12	Obs. 13	2.5	5	-	-
	Simul. 9.43	2.8	4.64	0.674	0.621

Tabla A.43: Percentiles de las longitudes de racha observada y simulada por *CM est*, Agoncillo (1978-1992).

## Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	5	2	1	—
	Simul.	3.95	1.72	1.8	0.804
2	Obs.	4	2	2	—
	Simul.	3.84	1.65	1.65	0.169
3	Obs.	5.2	2	2	—
	Simul.	4.24	1.8	1.74	0.986
4	Obs.	5.2	2	2	—
	Simul.	4.73	1.9	1.92	0.249
5	Obs.	4	2	2	—
	Simul.	3.98	1.5	1.58	0.34
6	Obs.	3.6	2	1	—
	Simul.	3.01	1	1	0.31
7	Obs.	2.1	1	1	—
	Simul.	2.19	1	0.8	0.339
8	Obs.	2	1	1	—
	Simul.	2.12	1	0.66	0.744
9	Obs.	3	1	1	—
	Simul.	2.44	1	0.84	0.406
10	Obs.	3.5	1.5	1	—
	Simul.	3.28	1.1	1.19	1
11	Obs.	6	2	3	—
	Simul.	4.02	1.62	1.65	0.117
12	Obs.	3	2	2	—
	Simul.	4.31	1.75	1.84	0.802

## Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	9	2	4	—
	Simul.	9.42	3.02	4.64	0.052
2	Obs.	11	3	6	—
	Simul.	10.11	3.02	4.79	0.979
3	Obs.	9.3	3	4	—
	Simul.	8.36	2.52	4.03	0.904
4	Obs.	10.8	2	4	—
	Simul.	7.21	2.2	3.35	0.85
5	Obs.	9.2	2	4	—
	Simul.	7.88	2.48	3.84	0.636
6	Obs.	14	4	6	—
	Simul.	10.55	3.1	5.16	0.498
7	Obs.	19	5	7	—
	Simul.	15.5	4.8	8.1	0.996
8	Obs.	21	5.5	6	—
	Simul.	15.36	4.6	7.2	0.669
9	Obs.	12.4	4	6	—
	Simul.	12.92	4.25	5.91	0.55
10	Obs.	12	3	6	—
	Simul.	9.85	2.92	4.64	0.971
11	Obs.	8.9	3	4	—
	Simul.	8.88	2.7	4.3	0.708
12	Obs.	13	2.5	5	—
	Simul.	9.61	2.85	4.58	0.836

Tabla A.44: Percentiles de las longitudes de racha observada y simulada por *CM temp*, Agoncillo (1978-1992).

Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 5	2	1	-	-
	Simul. 4.08	1.78	1.7	0.775	0.936
2	Obs. 4	2	2	-	-
	Simul. 4.42	1.95	1.85	0.321	0.097
3	Obs. 5.2	2	2	-	-
	Simul. 4.81	1.9	1.94	0.997	0.908
4	Obs. 5.2	2	2	-	-
	Simul. 4.45	1.92	2	0.741	0.309
5	Obs. 4	2	2	-	-
	Simul. 4.11	1.95	1.85	0.816	0.419
6	Obs. 3.6	2	1	-	-
	Simul. 3.15	1.32	1.12	0.998	0.458
7	Obs. 2.1	1	1	-	-
	Simul. 2.71	1.05	0.95	0.999	0.532
8	Obs. 2	1	1	-	-
	Simul. 2.57	1	0.88	1	0.849
9	Obs. 3	1	1	-	-
	Simul. 2.88	1.12	0.98	1	0.542
10	Obs. 3.5	1.5	1	-	-
	Simul. 3.91	1.55	1.4	1	0.782
11	Obs. 6	2	3	-	-
	Simul. 4.21	1.95	2	0.286	0.435
12	Obs. 3	2	2	-	-
	Simul. 4.62	1.9	1.85	0.536	0.447

Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 9	2	4	-	-
	Simul. 10.6	2.3	4.39	0.709	0.461
2	Obs. 11	3	6	-	-
	Simul. 9.4	2.3	4	0.738	0.196
3	Obs. 9.3	3	4	-	-
	Simul. 8.1	2.33	3.81	0.747	0.211
4	Obs. 10.8	2	4	-	-
	Simul. 8.06	2.3	3.51	0.9	0.526
5	Obs. 9.2	2	4	-	-
	Simul. 9.24	2.55	3.9	0.261	0.094
6	Obs. 14	4	6	-	-
	Simul. 11.12	3.58	5.35	0.728	0.258
7	Obs. 19	5	7	-	-
	Simul. 17.6	5.52	7.34	0.666	0.414
8	Obs. 21	5.5	6	-	-
	Simul. 18.09	5.82	8.69	0.706	0.882
9	Obs. 12.4	4	6	-	-
	Simul. 15.73	5.12	7.31	0.671	0.28
10	Obs. 12	3	6	-	-
	Simul. 10.36	2.85	4.46	0.884	0.817
11	Obs. 8.9	3	4	-	-
	Simul. 9.53	2.68	4.11	0.814	0.805
12	Obs. 13	2.5	5	-	-
	Simul. 10.38	2.25	4.58	0.867	0.261

Tabla A.45: Percentiles de las longitudes de racha observada y simulada por *CM pres*, Agoncillo (1978-1992).

## Rachas húmedas

Mes		$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	5	2	1	-	-
	Simul.	4.26	1.85	1.74	0.986	0.713
2	Obs.	4	2	2	-	-
	Simul.	4.47	1.85	1.9	0.418	0.105
3	Obs.	5.2	2	2	-	-
	Simul.	4.24	2	1.82	0.995	0.894
4	Obs.	5.2	2	2	-	-
	Simul.	4.49	2	1.95	0.767	0.245
5	Obs.	4	2	2	-	-
	Simul.	4.05	1.95	1.88	0.911	0.427
6	Obs.	3.6	2	1	-	-
	Simul.	3.13	1.05	1.05	0.813	0.219
7	Obs.	2.1	1	1	-	-
	Simul.	2.6	1	0.89	0.931	0.321
8	Obs.	2	1	1	-	-
	Simul.	2.2	1	0.81	1	0.639
9	Obs.	3	1	1	-	-
	Simul.	2.61	1	0.96	0.942	0.291
10	Obs.	3.5	1.5	1	-	-
	Simul.	3.45	1.5	1.31	1	0.897
11	Obs.	6	2	3	-	-
	Simul.	4.41	2	1.95	0.465	0.752
12	Obs.	3	2	2	-	-
	Simul.	4.38	1.82	1.94	0.61	0.37

## Rachas secas

Mes		$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	9	2	4	-	-
	Simul.	10.86	2.6	4.7	0.605	0.381
2	Obs.	11	3	6	-	-
	Simul.	10.37	2.35	4.18	0.834	0.233
3	Obs.	9.3	3	4	-	-
	Simul.	8.59	2.42	3.84	0.85	0.283
4	Obs.	10.8	2	4	-	-
	Simul.	7.55	1.95	3.22	0.892	0.246
5	Obs.	9.2	2	4	-	-
	Simul.	7.76	2.3	3.61	0.606	0.399
6	Obs.	14	4	6	-	-
	Simul.	11.32	3.22	5.16	0.551	0.126
7	Obs.	19	5	7	-	-
	Simul.	16.52	5.22	7.32	0.816	0.477
8	Obs.	21	5.5	6	-	-
	Simul.	16.02	5.32	7.66	0.846	0.561
9	Obs.	12.4	4	6	-	-
	Simul.	15.33	5.1	6.98	0.776	0.407
10	Obs.	12	3	6	-	-
	Simul.	9.91	2.82	4.2	0.598	0.523
11	Obs.	8.9	3	4	-	-
	Simul.	10.14	2.7	4.6	0.865	0.986
12	Obs.	13	2.5	5	-	-
	Simul.	11.93	2.35	4.81	0.744	0.253

Tabla A.46: Percentiles de las longitudes de racha observada y simulada por *CM temp y pres*, Agoncillo (1978-1992).

AIC:	2062.42	BIC:	2095.48
Estad. HL	–	p-valor	–
% variabilidad explicada por modelo			11.42
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	70.54
Primavera	Verano	Otoño	Invierno
69.57	76.74	68.13	67.63
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	15.44
	Húmedo	0	80.53
%NAS		Anual	31.2
Primavera	Verano	Otoño	Invierno
28.57	28.19	30.62	35.96
% días bien clasificados (frec. día)		Anual	64.79
Primavera	Verano	Otoño	Invierno
70.87	52.83	67.91	67.63
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	83.47	0
	Húmedo	16.15	100
%NAS		Anual	34.92
Primavera	Verano	Otoño	Invierno
34.95	27.91	38.4	40.16
Índice relativo de Brier		Anual	11.47
Primavera	Verano	Otoño	Invierno
9.37	12.07	10.36	10.23
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9826	Coef. eficiencia	0.6437
Índice de acuerdo	0.8224	% medio error	3.207
Días de precipitación observados y estimados por años			
Coef. correlación	0.9934	Coef. eficiencia	0.5908
Índice de acuerdo	0.7947	% medio error	1.132

Tabla A.47: Medidas de bondad de ajuste de *CM hom*, Agoncillo periodo de validación (1993-1997).

AIC:	2069.24	BIC:	2118.83
Estad. HL	22.98	p-valor	0
% variabilidad explicada por modelo			11.2
Autocorrelación orden 1 en residuos			0.02
% días bien clasificados (0.5)		Anual	70.81
Primavera	Verano	Otoño	Invierno
70.65	77.39	68.13	66.96
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	32.43
	Húmedo	0	67.66
%NAS		Anual	27.78
Primavera	Verano	Otoño	Invierno
34.15	7.14	24.08	35.22
% días bien clasificados (frec. día)		Anual	70.48
Primavera	Verano	Otoño	Invierno
69.57	75.22	69.67	67.41
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	96.91	0
	Húmedo	4.23	100
%NAS		Anual	36.81
Primavera	Verano	Otoño	Invierno
34.27	34.86	37.27	40
Índice relativo de Brier		Anual	11.25
Primavera	Verano	Otoño	Invierno
8.01	12.76	9.45	11
Días de precipitación observados y estimados por meses			
Coef. correlación	0.7848	Coef. eficiencia	0.5994
Índice de acuerdo	0.8742	% medio error	0.9122
Días de precipitación observados y estimados por años			
Coef. correlación	0.9532	Coef. eficiencia	0.449
Índice de acuerdo	0.7089	% medio error	1.619

Tabla A.48: Medidas de bondad de ajuste de *CM est*, Agoncillo, periodo de validación (1993-1997).

AIC:	1966.1	BIC:	2043.23
Estad. HL	23.29	p-valor	0
% variabilidad explicada por modelo			17.05
Autocorrelación orden 1 en residuos			0.01
% días bien clasificados (0.5)		Anual	73.55
Primavera	Verano	Otoño	Invierno
73.91	80.22	72.97	66.96
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	99.8	60.62
	Húmedo	4.23	57.1
%NAS		Anual	27.59
Primavera	Verano	Otoño	Invierno
31.03	15.74	27.22	31.02
% días bien clasificados (frec. día)		Anual	69.99
Primavera	Verano	Otoño	Invierno
71.74	71.52	69.23	67.41
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	89.14	14.67
	Húmedo	26.54	91.09
%NAS		Anual	38.63
Primavera	Verano	Otoño	Invierno
38.68	35.15	39.91	40.24
Índice relativo de Brier		Anual	17.1
Primavera	Verano	Otoño	Invierno
18.4	17.65	17.93	11.14
Días de precipitación observados y estimados por meses			
Coef. correlación	0.8782	Coef. eficiencia	0.5761
Índice de acuerdo	0.8693	% medio error	9.324
Días de precipitación observados y estimados por años			
Coef. correlación	0.8245	Coef. eficiencia	-1.541
Índice de acuerdo	0.5638	% medio error	11.030

Tabla A.49: Medidas de bondad de ajuste de *CM temp*, Agoncillo, periodo de validación (1993-1997).

AIC:	1750.94	BIC:	1850.12
Estad. HL	14.51	p-valor	0.07
% variabilidad explicada por modelo			28.09
Autocorrelación orden 1 en residuos			-0.01
% días bien clasificados (0.5)		Anual	77.44
Primavera	Verano	Otoño	Invierno
77.61	80.87	76.48	74.72
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	95.82	56.37
	Húmedo	30	75.25
%NAS		Anual	42.62
Primavera	Verano	Otoño	Invierno
45.5	24.14	43.68	48.88
% días bien clasificados (frec. día)		Anual	73.49
Primavera	Verano	Otoño	Invierno
74.35	71.52	73.85	74.28
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	82.67	24.32
	Húmedo	60	96.7
%NAS		Anual	48.12
Primavera	Verano	Otoño	Invierno
48.25	38.79	51.23	53.04
Índice relativo de Brier		Anual	28.13
Primavera	Verano	Otoño	Invierno
30.65	23.63	26.27	28
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9187	Coef. eficiencia	0.8348
Índice de acuerdo	0.9559	% medio error	3.606
Días de precipitación observados y estimados por años			
Coef. correlación	0.7963	Coef. eficiencia	0.530
Índice de acuerdo	0.8697	% medio error	2.246

Tabla A.50: Medidas de bondad de ajuste de *CM pres*, Agoncillo, periodo de validación (1993-1997).

AIC:	1662.5	BIC:	1772.69
Estad. HL	17.61	p-valor	0.02
% variabilidad explicada por modelo			32.04
Autocorrelación orden 1 en residuos			-0.01
% días bien clasificados (0.5)		Anual	78.92
Primavera	Verano	Otoño	Invierno
79.57	81.96	78.68	75.39
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	96.51	66.8
	Húmedo	30.77	72.28
%NAS		Anual	43.71
Primavera	Verano	Otoño	Invierno
45.35	28.45	46.99	47.89
% días bien clasificados (frec. día)		Anual	74.1
Primavera	Verano	Otoño	Invierno
76.96	70.65	75.16	73.61
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	81.97	33.2
	Húmedo	61.92	93.4
%NAS		Anual	48.42
Primavera	Verano	Otoño	Invierno
49.76	38.64	52.52	52.02
Índice relativo de Brier		Anual	32.08
Primavera	Verano	Otoño	Invierno
35.79	27.97	32.46	28.59
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9473	Coef. eficiencia	0.8872
Índice de acuerdo	0.9684	% medio error	1.036
Días de precipitación observados y estimados por años			
Coef. correlación	0.7896	Coef. eficiencia	0.372
Índice de acuerdo	0.8717	% medio error	2.358

Tabla A.51: Medidas de bondad de ajuste de *CM temp y pres*, Agoncillo, periodo de validación (1993-1997).

Longitud	Rachas secas		Rachas húmedas	
	Observada	Ajustada	Observada	Ajustada
1	0.27	0.284	0.462	0.448
2	0.197	0.154	0.223	0.286
3	0.097	0.107	0.15	0.126
4	0.112	0.076	0.081	0.061
5	0.085	0.063	0.05	0.034
6	0.039	0.053	0.012	0.019
7	0.023	0.044	0.004	0.011
8	0.019	0.037	0.012	0.006
9	0.023	0.03	0	0.004
10	0.027	0.025	0.004	0.002
11	0.023	0.021	0	0.001
12	0.008	0.018	0	0.001
13	0.015	0.015	0	0
14	0.008	0.012	0	0
15	0.015	0.01	0	0
16	0.004	0.008	0	0
17	0.008	0.007	0	0
18	0.004	0.006	0	0
19	0.004	0.005	0	0
$\geq 20$	0.019	0.012	0.004	0
p-valor test $X^2$	0.143		0.004	

Tabla A.52: Distribuciones de las longitudes de racha observada y teórica según *CM hom*, Agoncillo (1993-1997).

Rachas secas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor
1	3.08	2	3.51	2	0.175
2	6.17	4	7.86	4.75	0.013
3	7.17	4.5	6.29	6	0.006
4	4.2	3.5	3.33	3	0.368
5	3.28	2	4.69	3	0.173
6	7	5.5	5.07	3.75	0.036
7	8.13	4	8.92	8	0.635
8	6.27	3	7.7	9	0.984
9	4.76	3	5.15	5	0.921
10	4.23	3.5	3.35	3.75	0.481
11	3.33	2	4.06	2	0.219
12	2.9	2	1.9	4	0.015
Teórica	4.96	3	5.1	6	—
Rachas húmedas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor
1	2.64	2	1.79	2.75	0.306
2	2.32	2	1.7	2	0.915
3	1.47	1	0.8	1	0.074
4	2.38	2	1.4	2	0.643
5	2.24	1	2.12	2	0.057
6	2.29	2	1.9	2	0.952
7	2.42	2.5	1.16	1.25	0.169
8	1.5	1	0.8	1	0.229
9	2.42	2	1.5	2	0.498
10	2	2	1.19	2	0.605
11	2.22	2	1.48	2	0.832
12	2.14	2	1.46	2	0.748
Teórica	2.14	2	1.58	2	—

Tabla A.53: Distribuciones de las longitudes de racha, observada y teórica según *CM hom*, por meses, Agoncillo (1993-1997).

## Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	4.9	2	2.75	-
	Simul.	4.36	1.9	1.78	0.976
2	Obs.	4	2	2	-
	Simul.	3.99	1.78	1.56	1
3	Obs.	3	1	1	-
	Simul.	4.3	1.92	1.85	0.084
4	Obs.	5	2	2	-
	Simul.	5.05	1.9	2.09	0.989
5	Obs.	4	1	2	-
	Simul.	4.42	1.85	1.91	0.158
6	Obs.	4.4	2	2	-
	Simul.	3.38	1.68	1.26	1
7	Obs.	3	2.5	1.25	-
	Simul.	2.76	1.2	0.98	0.084
8	Obs.	2	1	1	-
	Simul.	2.9	1.18	0.91	1
9	Obs.	4.2	2	2	-
	Simul.	2.69	1.23	0.9	0.102
10	Obs.	3.6	2	2	-
	Simul.	3.27	1.35	1.24	0.885
11	Obs.	4.4	2	2	-
	Simul.	4.35	1.9	1.82	1
12	Obs.	4.2	2	2	-
	Simul.	4.21	1.9	1.51	0.918

## Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	8.6	2	2	-
	Simul.	11.13	2.85	4.99	0.157
2	Obs.	10.6	4	4.75	-
	Simul.	8.54	3	3.82	0.617
3	Obs.	14.8	4.5	6	-
	Simul.	7.99	2.65	3.85	0.005
4	Obs.	8.3	3.5	3	-
	Simul.	7.89	2.48	3.45	0.668
5	Obs.	5	2	3	-
	Simul.	8.9	2.65	4.26	0.489
6	Obs.	14.5	5.5	3.75	-
	Simul.	11.67	3.52	4.69	0.036
7	Obs.	21.6	4	8	-
	Simul.	19.28	5.55	9.15	0.974
8	Obs.	15.5	3	9	-
	Simul.	19.73	7.08	9.35	0.096
9	Obs.	9.2	3	5	-
	Simul.	13.3	4.9	6.61	0.863
10	Obs.	9	3.5	3.75	-
	Simul.	10.02	3.22	4.89	0.979
11	Obs.	4.7	2	2	-
	Simul.	10.53	3.38	5.28	0.178
12	Obs.	5.2	2	4	-
	Simul.	9.11	2.62	4.25	0.543

Tabla A.54: Percentiles de las longitudes de racha observada y simulada por *CM est*, Agoncillo (1993-1997).

Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 4.9	2	2.75	-	-
	Simul. 3.63	1.48	1.49	0.371	0.039
2	Obs. 4	2	2	-	-
	Simul. 3.34	1.42	1.35	0.89	0.239
3	Obs. 3	1	1	-	-
	Simul. 3.39	1.48	1.38	0.548	0.132
4	Obs. 5	2	2	-	-
	Simul. 3.33	1.27	1.38	0.159	0.021
5	Obs. 4	1	2	-	-
	Simul. 3.43	1.5	1.25	0.66	0.958
6	Obs. 4.4	2	2	-	-
	Simul. 2.45	1.23	0.76	0.714	0.078
7	Obs. 3	2.5	1.25	-	-
	Simul. 2.18	1	0.55	0.01	0
8	Obs. 2	1	1	-	-
	Simul. 2.1	1	0.44	0.984	0.3
9	Obs. 4.2	2	2	-	-
	Simul. 2.06	1	0.64	0.02	0
10	Obs. 3.6	2	2	-	-
	Simul. 3.02	1.32	1.11	0.724	0.2
11	Obs. 4.4	2	2	-	-
	Simul. 3.34	1.27	1.26	0.821	0.183
12	Obs. 4.2	2	2	-	-
	Simul. 4.1	1.82	1.69	1	0.875

Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 8.6	2	2	-	-
	Simul. 10.75	3.28	5.15	0.015	0.011
2	Obs. 10.6	4	4.75	-	-
	Simul. 10.82	4.18	5.82	0.728	0.907
3	Obs. 14.8	4.5	6	-	-
	Simul. 10.61	4.03	5.14	0.179	0.111
4	Obs. 8.3	3.5	3	-	-
	Simul. 9.11	3.22	4.42	1	0.752
5	Obs. 5	2	3	-	-
	Simul. 8.48	2.7	4.26	0.341	0.096
6	Obs. 14.5	5.5	3.75	-	-
	Simul. 12.48	4.1	5.7	0.114	0.105
7	Obs. 21.6	4	8	-	-
	Simul. 15.69	4.75	7.29	0.946	0.821
8	Obs. 15.5	3	9	-	-
	Simul. 15.93	5.85	7.8	0.216	0.13
9	Obs. 9.2	3	5	-	-
	Simul. 12.57	4.4	5.55	0.905	0.272
10	Obs. 9	3.5	3.75	-	-
	Simul. 10.75	3.42	5.45	0.913	0.869
11	Obs. 4.7	2	2	-	-
	Simul. 8.81	2.85	4.01	0.199	0.147
12	Obs. 5.2	2	4	-	-
	Simul. 8.72	2.82	3.82	0.567	0.346

Tabla A.55: Percentiles de las longitudes de racha observada y simulada por *CM temp*, Agoncillo (1993-1997).

## Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	4.9	2	2.75	-
	Simul.	4.13	1.98	1.82	0.932
2	Obs.	4	2	2	-
	Simul.	3.54	1.7	1.4	0.995
3	Obs.	3	1	1	-
	Simul.	3.35	1.35	1.14	0.687
4	Obs.	5	2	2	-
	Simul.	4.88	1.8	2.02	0.998
5	Obs.	4	1	2	-
	Simul.	4.34	1.8	1.84	0.498
6	Obs.	4.4	2	2	-
	Simul.	3.37	1.3	1.35	1
7	Obs.	3	2.5	1.25	-
	Simul.	2.62	1.1	0.9	0.041
8	Obs.	2	1	1	-
	Simul.	2.44	1.08	0.81	1
9	Obs.	4.2	2	2	-
	Simul.	3.14	1.35	1.09	0.181
10	Obs.	3.6	2	2	-
	Simul.	3.55	1.55	1.36	0.995
11	Obs.	4.4	2	2	-
	Simul.	4.76	2	2.22	1
12	Obs.	4.2	2	2	-
	Simul.	4.81	2	2.31	1

## Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	8.6	2	2	-
	Simul.	11.04	2.08	4.2	0.499
2	Obs.	10.6	4	4.75	-
	Simul.	9.72	3.1	4.39	0.624
3	Obs.	14.8	4.5	6	-
	Simul.	11.99	3.22	5	0.061
4	Obs.	8.3	3.5	3	-
	Simul.	7.91	2.7	3.62	0.757
5	Obs.	5	2	3	-
	Simul.	6.73	2.15	2.91	0.973
6	Obs.	14.5	5.5	3.75	-
	Simul.	10.54	3.68	4.79	0.042
7	Obs.	21.6	4	8	-
	Simul.	14.46	5.35	6.42	0.798
8	Obs.	15.5	3	9	-
	Simul.	12.57	4.7	6.46	0.535
9	Obs.	9.2	3	5	-
	Simul.	10.55	4.15	5.21	0.896
10	Obs.	9	3.5	3.75	-
	Simul.	9.86	3.35	4.69	0.989
11	Obs.	4.7	2	2	-
	Simul.	6.82	1.9	3.14	0.901
12	Obs.	5.2	2	4	-
	Simul.	6.44	1.95	2.95	0.917

Tabla A.56: Percentiles de las longitudes de racha observada y simulada por *CM pres*, Agoncillo (1993-1997).

Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 4.9	2	2.75	-	-
	Simul. 4.4	1.75	1.84	0.916	0.236
2	Obs. 4	2	2	-	-
	Simul. 3.35	1.4	1.42	0.63	0.18
3	Obs. 3	1	1	-	-
	Simul. 3.26	1.4	1.38	0.569	0.159
4	Obs. 5	2	2	-	-
	Simul. 4.02	1.78	1.61	0.97	0.304
5	Obs. 4	1	2	-	-
	Simul. 4.15	1.88	1.76	0.319	0.265
6	Obs. 4.4	2	2	-	-
	Simul. 3	1.27	1.16	0.995	0.369
7	Obs. 3	2.5	1.25	-	-
	Simul. 2.41	1.1	0.94	0.044	0.001
8	Obs. 2	1	1	-	-
	Simul. 2.66	1.12	0.95	1	0.874
9	Obs. 4.2	2	2	-	-
	Simul. 2.9	1.15	1.06	0.136	0.011
10	Obs. 3.6	2	2	-	-
	Simul. 3.02	1.32	1.16	0.602	0.255
11	Obs. 4.4	2	2	-	-
	Simul. 3.88	1.85	1.65	1	0.957
12	Obs. 4.2	2	2	-	-
	Simul. 4.91	2.02	2.28	0.767	0.201

Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 8.6	2	2	-	-
	Simul. 13.16	2.42	4.84	0.243	0.08
2	Obs. 10.6	4	4.75	-	-
	Simul. 10.1	3.35	4.42	0.724	0.394
3	Obs. 14.8	4.5	6	-	-
	Simul. 11.79	3.48	6.3	0.087	0.075
4	Obs. 8.3	3.5	3	-	-
	Simul. 8.57	2.88	4.16	0.91	0.456
5	Obs. 5	2	3	-	-
	Simul. 7.67	2.02	3.12	0.906	0.53
6	Obs. 14.5	5.5	3.75	-	-
	Simul. 10.32	3.4	5.22	0.031	0.027
7	Obs. 21.6	4	8	-	-
	Simul. 15.04	4.78	6.91	0.916	0.95
8	Obs. 15.5	3	9	-	-
	Simul. 13.91	4.6	6.25	0.618	0.284
9	Obs. 9.2	3	5	-	-
	Simul. 10.65	3.5	4.97	0.994	0.705
10	Obs. 9	3.5	3.75	-	-
	Simul. 9.1	3	4.06	0.997	0.626
11	Obs. 4.7	2	2	-	-
	Simul. 7.24	2	3.39	0.917	0.997
12	Obs. 5.2	2	4	-	-
	Simul. 6.99	2.08	3.39	0.911	0.877

Tabla A.57: Percentiles de las longitudes de racha observada y simulada por *CM temp* y *pres*, Agoncillo (1993-1997).

#### **A.1.4 Zaragoza**

Cadena de Markov homogénea ( <i>CM hom</i> )			
Término	Coefficiente	Error std.	Estadístico <i>t</i>
$\beta_0$	-1.718	0.06586	-26.080
$Y_{t-1}$	1.427	0.1271	11.230
$Y_{t-2}$	0.5327	0.1429	3.727
$Y_{t-1} : Y_{t-2}$	-0.4514	0.2175	-2.075
Cadena de Markov estacional ( <i>CM est</i> )			
Término	Coefficiente	Error std.	Estadístico <i>t</i>
$\beta_0$	-1.686	0.06362	-26.500
$Y_{t-1}$	1.276	0.1065	11.980
$Y_{t-2}$	0.2767	0.1107	2.498
$S1$	-0.1787	0.08418	-2.123
$C1$	0.2527	0.08522	2.965
$S2$	-0.225	0.06839	-3.290
$C2$	0.007367	0.06917	0.1065
$Y_{t-1} : S1$	0.2978	0.1448	2.057
$Y_{t-1} : C1$	-0.1606	0.146	-1.101
Cadena de Markov con temperaturas mínima y máxima ( <i>CM temp</i> )			
Término	Coefficiente	Error std.	Estadístico <i>t</i>
$\beta_0$	-0.1037	0.1856	-0.5584
$Y_{t-1}$	1.050	0.1157	9.071
$Y_{t-2}$	0.3314	0.1181	2.806
$TDIF_t$	-0.02753	0.001807	-15.240
$TMIN_t$	0.003945	9.976e-4	3.955
$TDIF_{t-1}$	0.008175	0.001732	4.721
Cadena de Markov con temperaturas horarias			
Término	Coefficiente	Error std.	Estadístico <i>t</i>
$\beta_0$	0.2779	0.1413	1.967
$Y_{t-1}$	0.5707	0.2125	2.686
$Y_{t-2}$	0.7132	0.2327	3.065
$S1$	-0.04266	0.07436	-0.5736
$C1$	-0.5647	0.08623	-6.549
$cambio.T_t$	-0.01735	0.001226	-14.150
$T07_t - T07_{t-1}$	0.009252	0.001778	5.204
$Y_{t-1} : cambio.T_t$	0.00503	0.001991	2.526
$Y_{t-2} : cambio.T_t$	-0.005067	0.002255	-2.247

Tabla A.58: Modelos de cadena de Markov homogéneo, estacional y con información de temperaturas para el proceso de ocurrencia en Zaragoza.

Cadena de Markov con presión			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	120.600	10.840	11.120
$Y_{t-1}$	-57.130	16.880	-3.385
$P18_t$	-0.01237	0.001102	-11.220
$cambio.presion_t$	0.02962	0.003016	9.821
$\Delta P.24.18_{t-1}$	-0.008129	0.003892	-2.089
$Y_{t-1} : P18_t$	0.005915	0.001716	3.446
Cadena de Markov con presión y temperatura ( <i>CM superficie</i> )			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	122.400	11.860	10.320
$Y_{t-1}$	-53.390	17.540	-3.044
$P18_t$	-0.02232	0.00246	-9.076
$cambio.presion_t$	0.01875	0.0033	5.682
$cambio.T_t$	-0.01903	0.001577	-12.070
$T07_t - T07_{t-1}$	0.004594	0.001958	2.346
$P07_t$	0.009906	0.002397	4.132
$T18_t$	0.00277	0.001026	2.700
$Y_{t-1} : P18_t$	0.005469	0.001779	3.074
$Y_{t-1} : cambio.T_t$	0.005402	0.002056	2.627
Cadena de Markov con presión, temperatura y humedad			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	141.400	12.240	11.550
$Y_{t-1}$	-43.190	18.750	-2.303
$P18_t$	-0.0144	0.00124	-11.610
$cambio.presion_t$	0.01314	0.003309	3.969
$cambio.T_t$	-0.01145	0.001184	-9.668
$T07_t - T07_{t-1}$	0.009962	0.002157	4.618
$(2 * z.H18_t + z.H13_t + 2 * z.H07_t)/5$	0.1093	0.007103	15.390
$z.H13_{t-1}$	-0.02772	0.005267	-5.263
$Y_{t-1} : P18_t$	0.004479	0.001905	2.351
Cadena de Markov con información de superficie, y con las altura, temperatura y humedad del radiosondeo de las 12h			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	104.600	10.320	10.130
$Y_{t-1}$	0.6743	0.1569	4.297
$P18_t$	-0.01057	0.001048	-10.090
$cambio.T_t$	-0.01234	0.001173	-10.520
$T07_t - T07_{t-1}$	0.007424	0.002366	3.138
$(2 * z.H18_t + z.H13_t + 2 * z.H07_t)/5$	0.095	0.007616	12.470
$z.H13_{t-1}$	-0.02538	0.005648	-4.493
$R700.12_t$	-0.007753	9.477e-4	-8.181
$z.T85/50.12_t$	0.008983	0.002166	4.148

Tabla A.59: Modelos de cadena de Markov con variables de superficie y con altura, temperatura y punto de rocío del radiosondeo de las 12h para el proceso de ocurrencia en Zaragoza.

Cadena de Markov con información de superficie, y con las alturas, temperaturas, humedad y vientos del radiosondeo de las 12h			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	90.780	11.130	8.159
$Y_{t-1}$	0.629	0.1635	3.848
$P18_t$	-0.009205	0.001125	-8.180
$cambio.T_t$	-0.01292	0.001338	-9.660
$T07_t - T07_{t-1}$	0.006284	0.002444	2.572
$(2 * z.H18_t + z.H13_t + 2 * z.H07_t)/5$	0.08979	0.008565	10.480
$z.H13_{t-1}$	-0.01875	0.005858	-3.201
$R700.12_t$	-0.007752	9.754e-4	-7.947
$z.T85/50.12_t$	0.008573	0.002447	3.503
$vV500.12_t$	0.01149	0.004819	2.384
$dVSUP.12.este_t : dV500.12.cos_t$	0.1174	0.2132	0.5508
$dVSUP.12.este_t : dV500.12.sen_t$	-0.7812	0.1957	-3.992
$dVSUP.12.NW_t : dV500.12.cos_t$	-0.5026	0.1688	-2.978
$dVSUP.12.NW_t : dV500.12.sen_t$	0.0322	0.1536	0.2096
$dVSUP.12.NW_t : vVSUP.12_t$	-0.05707	0.01652	-3.454
$dVSUP.12.NW_t : vV850.12_t$	0.03989	0.01092	3.653
Cadena de Markov con información de superficie y de los radiosondeos de las 0 y las 12 horas ( <i>CM sondeos</i> )			
Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	93.370	11.920	7.833
$Y_{t-1}$	0.7017	0.1747	4.017
$P18_t$	-0.009455	0.001205	-7.847
$cambio.T_t$	-0.01353	0.001443	-9.379
$T07_t - T07_{t-1}$	0.005451	0.002636	2.068
$(2 * z.H18_t + z.H13_t + 2 * z.H07_t)/5$	0.09216	0.009081	10.150
$z.H13_{t-1}$	-0.01783	0.006232	-2.861
$R700.12_t$	-0.008504	0.001047	-8.122
$z.T85/50.12_t$	0.008188	0.002608	3.139
$vV500.12_t$	0.01055	0.005157	2.045
$dVSUP.12.este_t : dV500.12.cos_t$	-0.2193	0.2475	-0.8861
$dVSUP.12.este_t : dV500.12.sen_t$	-0.8741	0.2242	-3.899
$dVSUP.12.NW_t : dV500.12.cos_t$	-0.4977	0.1807	-2.755
$dVSUP.12.NW_t : dV500.12.sen_t$	0.03889	0.1626	0.2391
$dVSUP.12.NW_t : vVSUP.12_t$	-0.06923	0.01843	-3.756
$dVSUP.12.NW_t : vV850.12_t$	0.04512	0.01249	3.614
$dVSUP.00.este_t : dVSUP.12.SW_t$	2.509	0.7279	3.446
$dVSUP.00.calma_t : dVSUP.12.este_t$	-0.8247	0.3737	-2.207
$dVSUP.00.este_t : dV500.00.cos_t$	0.5435	0.2299	2.364
$dVSUP.00.este_t : dV500.00.sen_t$	-0.1279	0.2153	-0.5938

Tabla A.60: Modelos de cadena de Markov con información de los radiosondeos de las 0 y las 12h para el proceso de ocurrencia en Zaragoza.

Término	Coeficiente	Error std.	Estadístico $t$
$\beta_0$	89.610	12.900	6.949
$Y_{t-1}$	0.4126	0.1679	2.458
$P18_t$	-0.02661	0.005501	-4.838
$cambio.T_t$	-0.01916	0.002455	-7.803
$(2 * z.H18_t + z.H13_t + 2 * z.H07_t)/5$	0.04413	0.01075	4.106
$R700.12_t$	-0.006515	0.001151	-5.662
$z.T85/50.12_t$	0.01143	0.003013	3.793
$vV500.12_t$	0.01615	0.005204	3.103
$z.H00_{t+1}$	0.07383	0.01003	7.359
$z.H13_{t+1}$	-0.03213	0.00733	-4.384
$R850.00_{t+1}$	-0.008037	0.002047	-3.926
$cambio.T_{t+1}$	-0.005506	0.001829	-3.010
$T00_{t+1} - T00_t$	0.01545	0.004259	3.628
$P00_{t+1}$	0.01762	0.005293	3.328
$T00_{t+1}$	0.005874	0.001765	3.329
$dV SUP.12.este_t : dV500.12.cos_t$	0.04838	0.2518	0.1922
$dV SUP.12.este_t : dV500.12.sen_t$	-0.9736	0.2285	-4.261
$dV SUP.00.este_t : dV SUP.12.SW_t$	1.755	0.7551	2.324
$dV SUP.00.calma_t : dV SUP.12.este_t$	-1.039	0.3907	-2.660
$dV SUP.00.SW_{t+1} : dV SUP.12.calma_t$	2.688	1.203	2.235
$dV SUP.12.este_{t+1} : vV SUP.12_{t+1}$	-0.08805	0.03163	-2.784
$dV SUP.12.NW_{t+1} : vV SUP.12_{t+1}$	-0.0306	0.01195	-2.561

Tabla A.61: Cadena de Markov con información de superficie y de los radiosondeos incluso del día  $t + 1$  para el proceso de ocurrencia en Zaragoza.

		Deviance	Gr. lib.
Modelo nulo		2902.16	2709
Modelo ajustado		2708.82	2705
AIC:	2716.82	BIC:	2740.44
Estad. HL	-	p-valor	-
% variabilidad explicada por modelo			7.75
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	77.3
Primavera	Verano	Otoño	Invierno
78.88	83.23	73.9	73.45
Día $t - 1$		Seco	Humedo
Día $t$	Seco	100	100
	Húmedo	0	0
%NAS		Anual	0
Primavera	Verano	Otoño	Invierno
0	0	0	0
% días bien clasificados (frec. día)		Anual	63.71
Primavera	Verano	Otoño	Invierno
71.27	48.66	66.48	68.63
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	80.61	0
	Húmedo	14.12	100
%NAS		Anual	24.38
Primavera	Verano	Otoño	Invierno
27.17	18.97	24.92	29.25
Índice relativo de Brier		Anual	7.78
Primavera	Verano	Otoño	Invierno
10.37	6.79	3.63	8.13
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9951	Coef. eficiencia	0.5117
Índice de acuerdo	0.7122	% medio error	6.159
Días de precipitación observados y estimados por años			
Coef. correlación	0.997	Coef. eficiencia	0.5086
Índice de acuerdo	0.7104	% medio error	1.022

Tabla A.62: Medidas de bondad de ajuste de la cadena de Markov homogénea, Zaragoza (1990-1997).

		Deviance	Gr. lib.
Modelo nulo		2902.16	2709
Modelo ajustado		2685.26	2700
AIC:	2703.26	BIC:	2756.4
Estad. HL	10.1	p-valor	0.26
% variabilidad explicada por modelo			8.48
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	77.26
Primavera	Verano	Otoño	Invierno
79.19	83.38	72.94	73.91
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	84.1
	Húmedo	0	20.15
%NAS		Anual	8.06
Primavera	Verano	Otoño	Invierno
15.72	4.27	4.83	7.49
% días bien clasificados (frec. día)		Anual	72.76
Primavera	Verano	Otoño	Invierno
76.24	77	68.82	69.38
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	96.11	0
	Húmedo	6.63	100
%NAS		Anual	28.28
Primavera	Verano	Otoño	Invierno
29.82	24.76	26.77	31.19
Índice relativo de Brier		Anual	8.51
Primavera	Verano	Otoño	Invierno
10.93	7.09	4.62	9.06
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9237	Coef. eficiencia	0.8473
Índice de acuerdo	0.9537	% medio error	2.067
Días de precipitación observados y estimados por años			
Coef. correlación	0.9215	Coef. eficiencia	0.570
Índice de acuerdo	0.7713	% medio error	1.395

Tabla A.63: Medidas de bondad de ajuste de la cadena de Markov estacional, Zaragoza (1990-1997).

		Deviance	Gr. lib.
Modelo nulo		2902.16	2709
Modelo ajustado		2430.71	2703
AIC:	2442.71	BIC:	2478.14
Estad. HL	10.24	p-valor	0.25
% variabilidad explicada por modelo			17.87
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	79.7
Primavera	Verano	Otoño	Invierno
82.3	82.94	78.02	75.72
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	99.37	74.86
	Húmedo	6.34	52.61
%NAS		Anual	22.86
Primavera	Verano	Otoño	Invierno
22.45	9.45	27.93	25.81
% días bien clasificados (frec. día)		Anual	68.33
Primavera	Verano	Otoño	Invierno
73.45	66.77	66.62	66.82
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	77.8	18.79
	Húmedo	52.16	91.42
%NAS		Anual	33.18
Primavera	Verano	Otoño	Invierno
30.49	25.58	36.39	38.03
Índice relativo de Brier		Anual	17.9
Primavera	Verano	Otoño	Invierno
19.84	13.84	17.44	17.3
Días de precipitación observados y estimados por meses			
Coef. correlación	0.851	Coef. eficiencia	0.7242
Índice de acuerdo	0.9163	% medio error	2.155
Días de precipitación observados y estimados por años			
Coef. correlación	0.8345	Coef. eficiencia	0.6031
Índice de acuerdo	0.8192	% medio error	1.403

Tabla A.64: Medidas de bondad de ajuste de la cadena de Markov con temperaturas máximas y mínimas, Zaragoza (1990-1997).

		Deviance	Gr. lib.
Modelo nulo		2902.68	2710
Modelo ajustado		2072.43	2700
AIC:	2092.43	BIC:	2151.47
Estad. HL	6.31	p-valor	0.61
% variabilidad explicada por modelo			30.95
Autocorrelación orden 1 en residuos			0.02
% días bien clasificados (0.5)		Anual	82.77
Primavera	Verano	Otoño	Invierno
84.63	87.11	79.81	79.79
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	96.86	79.77
	Húmedo	33.14	58.96
%NAS		Anual	36.89
Primavera	Verano	Otoño	Invierno
38.89	28.69	38.75	37.96
% días bien clasificados (frec. día)		Anual	76.31
Primavera	Verano	Otoño	Invierno
82.14	77.78	72.94	72.85
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	84.68	31.79
	Húmedo	66.28	92.16
%NAS		Anual	42.63
Primavera	Verano	Otoño	Invierno
48.89	37.5	42.73	41.94
Índice relativo de Brier		Anual	30.97
Primavera	Verano	Otoño	Invierno
37.92	30.06	29.05	25.91
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9159	Coef. eficiencia	0.8344
Índice de acuerdo	0.9563	% medio error	0.8542
Días de precipitación observados y estimados por años			
Coef. correlación	0.8494	Coef. eficiencia	0.696
Índice de acuerdo	0.8883	% medio error	0.7465

Tabla A.65: Medidas de bondad de ajuste de la cadena de Markov con temperaturas y presión en superficie, Zaragoza (1990-1997).

		Deviance	Gr. lib.
Modelo nulo		2346.62	2173
Modelo ajustado		1273.8	2153
AIC:	1313.8	BIC:	1427.47
Estad. HL	7.3	p-valor	0.5
% variabilidad explicada por modelo			48.97
Autocorrelación orden 1 en residuos			0
% días bien clasificados (0.5)		Anual	86.93
Primavera	Verano	Otoño	Invierno
89.07	89.54	87.02	82.07
Día $t - 1$	Seco		Húmedo
Día $t$	Seco	96.49	82.97
	Húmedo	53.74	73.64
%NAS		Anual	52.43
Primavera	Verano	Otoño	Invierno
58.45	46.73	57.74	46.11
% días bien clasificados (frec. día)		Anual	82.47
Primavera	Verano	Otoño	Invierno
85.37	81.28	81.35	81.89
Día $t - 1$	Seco		Húmedo
Día $t$	Seco	86.68	57.97
	Húmedo	79.36	90.45
%NAS		Anual	52.55
Primavera	Verano	Otoño	Invierno
56.35	43.65	54.87	54.42
Índice relativo de Brier		Anual	48.99
Primavera	Verano	Otoño	Invierno
54.01	48.21	51.49	41.33
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9552	Coef. eficiencia	0.9037
Índice de acuerdo	0.9716	% medio error	1.921
Días de precipitación observados y estimados por años			
Coef. correlación	0.9191	Coef. eficiencia	0.8396
Índice de acuerdo	0.9569	% medio error	1.245

Tabla A.66: Medidas de bondad de ajuste de la cadena de Markov con información de superficie y de radiosondeos, Zaragoza (1990-1997).

Longitud	Rachas secas		Rachas húmedas	
	Observada	Ajustada	Observada	Ajustada
1	0.233	0.234	0.573	0.572
2	0.141	0.117	0.225	0.236
3	0.098	0.099	0.121	0.106
4	0.095	0.084	0.043	0.047
5	0.075	0.071	0.02	0.021
6	0.046	0.06	0.009	0.009
7	0.037	0.051	0.009	0.004
8	0.046	0.043	0	0.002
9	0.043	0.037	0	0.001
10	0.023	0.031	0	0
11	0.02	0.026	0	0
12	0.012	0.022	0	0
13	0.009	0.019	0	0
14	0.023	0.016	0	0
15	0.014	0.014	0	0
16	0.029	0.012	0	0
17	0.006	0.01	0	0
18	0.006	0.008	0	0
19	0.003	0.007	0	0
$\geq 20$	0.04	0.008	0	0
p-valor test $X^2$	0.259		0.761	

Tabla A.67: Distribuciones de las longitudes de racha observada y teórica según *CM hom*, Zaragoza (1990-1997).

Rachas secas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor
1	6.64	4	6.05	8	0.91
2	7.44	5	9.68	6	0.213
3	8.4	3.5	10.9	9	0.963
4	6.2	5.5	4.86	6.25	0.604
5	6.94	3	11.34	3.5	0.806
6	5.62	3	6.36	6	0.753
7	8.96	6	7.71	10.5	0.178
8	7.52	5	5.82	9.5	0.3
9	5.25	5.5	3.65	5	0.098
10	4.94	3	4.71	5.5	0.157
11	3.8	2	3.85	3.5	0.111
12	4.39	3	5.52	5	0.407
Teórica	5.98	4	5.81	6	—
Rachas húmedas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor
1	2.12	1	1.81	2	0.013
2	1.7	1	0.82	1	0.113
3	1.58	1	0.77	1	0.918
4	1.95	2	1.24	1	0.672
5	2.12	1	1.62	2	0.404
6	1.52	1	0.68	1	0.396
7	1.42	1	0.77	0.5	0.303
8	1.68	2	0.72	1	0.1
9	1.52	1	0.89	1	0.597
10	1.92	1.5	1.19	1.75	0.684
11	1.68	1	0.98	1	0.526
12	1.83	1	1.41	1	0.007
Teórica	1.77	1	1.2	1	—

Tabla A.68: Distribuciones de la longitud de racha, observada y teórica según *CM hom*, por meses, Zaragoza (1990-1997).

## Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	4.6	2	-	-
	Simul.	3.31	1.2	0.666	0.905
2	Obs.	3	1	-	-
	Simul.	3	1.02	0.908	0.329
3	Obs.	3	1	-	-
	Simul.	3.05	1.08	0.999	0.816
4	Obs.	3	2	-	-
	Simul.	3.32	1.2	0.985	0.444
5	Obs.	4	2	-	-
	Simul.	3.93	1.45	0.992	0.62
6	Obs.	2	1	-	-
	Simul.	2.84	1.1	1	0.952
7	Obs.	3	1	-	-
	Simul.	2.76	1.1	1	0.524
8	Obs.	3	2	-	-
	Simul.	2.66	1	0.154	0.052
9	Obs.	2	1	-	-
	Simul.	2.77	1	1	0.934
10	Obs.	3.3	1.5	-	-
	Simul.	3.13	1.05	0.492	0.089
11	Obs.	3	1	-	-
	Simul.	3.78	1.25	0.911	0.293
12	Obs.	4	1	-	-
	Simul.	3.48	1.25	0.707	0.355

## Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	15.2	4	-	-
	Simul.	13.77	4.12	0.907	0.688
2	Obs.	12.4	5	-	-
	Simul.	16.32	5.38	0.968	0.853
3	Obs.	18.6	3.5	-	-
	Simul.	17.01	6	0.736	0.441
4	Obs.	9.2	5.5	-	-
	Simul.	15.92	5.32	0.436	0.688
5	Obs.	16.5	3	-	-
	Simul.	15	5.3	0.235	0.102
6	Obs.	15	3	-	-
	Simul.	16.44	5.6	0.244	0.061
7	Obs.	16	6	-	-
	Simul.	17.55	5.88	0.725	0.466
8	Obs.	15	5	-	-
	Simul.	17.33	5.65	0.86	0.636
9	Obs.	9	5.5	-	-
	Simul.	13.29	4.75	0.673	0.804
10	Obs.	11	3	-	-
	Simul.	9.66	3.32	0.836	0.854
11	Obs.	8.7	2	-	-
	Simul.	8.72	2.85	0.781	0.371
12	Obs.	8	3	-	-
	Simul.	9.08	3.08	0.635	0.344

Tabla A.69: Percentiles de las longitudes de racha observada y simulada por *CM est*, Zaragoza (1990-1997).

Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 4.6	1	2	-	-
	Simul. 2.9	1.02	0.91	0.507	0.418
2	Obs. 3	1	1	-	-
	Simul. 3.08	1.2	0.96	0.824	0.327
3	Obs. 3	1	1	-	-
	Simul. 3.1	1.18	0.99	0.999	0.929
4	Obs. 3	2	1	-	-
	Simul. 2.61	1.1	0.65	0.377	0.047
5	Obs. 4	1	2	-	-
	Simul. 2.53	1	0.82	0.216	0.021
6	Obs. 2	1	1	-	-
	Simul. 2.6	1.1	0.68	0.974	0.456
7	Obs. 3	1	0.5	-	-
	Simul. 2.68	1	0.74	1	0.844
8	Obs. 3	2	1	-	-
	Simul. 2.86	1	0.79	0.17	0.07
9	Obs. 2	1	1	-	-
	Simul. 2.66	1.1	0.79	1	0.901
10	Obs. 3.3	1.5	1.75	-	-
	Simul. 2.99	1.12	1	0.59	0.11
11	Obs. 3	1	1	-	-
	Simul. 3.44	1.02	1.18	1	0.975
12	Obs. 4	1	1	-	-
	Simul. 2.94	1.15	0.99	0.434	0.989

Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 15.2	4	8	-	-
	Simul. 10.57	3.48	5.36	0.338	0.217
2	Obs. 12.4	5	6	-	-
	Simul. 11.6	3.85	5.35	0.349	0.127
3	Obs. 18.6	3.5	9	-	-
	Simul. 10.7	3.45	5.1	0.511	0.319
4	Obs. 9.2	5.5	6.25	-	-
	Simul. 13.45	4.18	5.75	0.769	0.305
5	Obs. 16.5	3	3.5	-	-
	Simul. 13.06	4.1	6.48	0.737	0.449
6	Obs. 15	3	6	-	-
	Simul. 15.25	5.1	7.72	0.474	0.155
7	Obs. 16	6	10.5	-	-
	Simul. 13.13	4.68	7	0.232	0.064
8	Obs. 15	5	9.5	-	-
	Simul. 12.89	4.35	5.39	0.288	0.081
9	Obs. 9	5.5	5	-	-
	Simul. 14.35	4.35	6.52	0.652	0.868
10	Obs. 11	3	5.5	-	-
	Simul. 12.7	4	5.16	0.438	0.46
11	Obs. 8.7	2	3.5	-	-
	Simul. 10.53	3.42	4.88	0.409	0.119
12	Obs. 8	3	5	-	-
	Simul. 13.45	4.22	6.06	0.161	0.02

Tabla A.70: Percentiles de las longitudes de racha observada y simulada por *CM temp*, Zaragoza (1990-1997).

## Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	4.6	1	2	-
	Simul.	2.51	1.1	0.8	0.412
2	Obs.	3	1	1	-
	Simul.	3.07	1.15	1.2	0.998
3	Obs.	3	1	1	-
	Simul.	3.42	1.5	1.39	0.95
4	Obs.	3	2	1	-
	Simul.	3.36	1.2	1.39	0.999
5	Obs.	4	1	2	-
	Simul.	2.98	1.08	0.98	0.496
6	Obs.	2	1	1	-
	Simul.	2.57	1.05	0.89	1
7	Obs.	3	1	0.5	-
	Simul.	3.07	1.1	1.12	0.967
8	Obs.	3	2	1	-
	Simul.	3.01	1.15	0.81	0.5
9	Obs.	2	1	1	-
	Simul.	3.44	1.35	1.24	0.888
10	Obs.	3.3	1.5	1.75	-
	Simul.	2.88	1.12	0.94	0.689
11	Obs.	3	1	1	-
	Simul.	3.24	1.2	1.27	1
12	Obs.	4	1	1	-
	Simul.	2.71	1.1	0.76	0.492

## Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	15.2	4	8	-
	Simul.	14.71	4.45	6.78	0.999
2	Obs.	12.4	5	6	-
	Simul.	15.13	3.92	5.98	0.461
3	Obs.	18.6	3.5	9	-
	Simul.	8.97	3.6	4.61	0.335
4	Obs.	9.2	5.5	6.25	-
	Simul.	10.5	3.25	4.91	0.323
5	Obs.	16.5	3	3.5	-
	Simul.	12.44	3.95	4.47	0.736
6	Obs.	15	3	6	-
	Simul.	12.37	4.08	5.51	0.535
7	Obs.	16	6	10.5	-
	Simul.	16.8	5.28	7.34	0.522
8	Obs.	15	5	9.5	-
	Simul.	13.68	4.55	6.22	0.523
9	Obs.	9	5.5	5	-
	Simul.	15.23	4.15	6.59	0.524
10	Obs.	11	3	5.5	-
	Simul.	14.96	4.05	6.34	0.346
11	Obs.	8.7	2	3.5	-
	Simul.	11.46	3.32	5.01	0.163
12	Obs.	8	3	5	-
	Simul.	14.97	4.75	7.42	0.106

Tabla A.71: Percentiles de las longitudes de racha observada y simulada por *CM superficie*, Zaragoza (1990-1997).

Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 4.6	1	2	-	-
	Simul. 2.6	1.02	0.7	0.26	0.216
2	Obs. 3	1	1	-	-
	Simul. 2.8	1.05	1.05	0.984	0.372
3	Obs. 3	1	1	-	-
	Simul. 2.9	1	0.92	1	0.739
4	Obs. 3	2	1	-	-
	Simul. 2.56	1.02	0.86	0.441	0.049
5	Obs. 4	1	2	-	-
	Simul. 2.68	1	0.88	0.24	0.034
6	Obs. 2	1	1	-	-
	Simul. 2.85	1.1	0.94	1	0.735
7	Obs. 3	1	0.5	-	-
	Simul. 2.93	1.32	1.06	0.638	0.19
8	Obs. 3	2	1	-	-
	Simul. 3.1	1.25	1.27	0.819	0.475
9	Obs. 2	1	1	-	-
	Simul. 4.3	1.5	1.42	0.523	0.052
10	Obs. 3.3	1.5	1.75	-	-
	Simul. 4	1.7	1.59	1	0.732
11	Obs. 3	1	1	-	-
	Simul. 4.03	1.75	1.81	0.426	0.052
12	Obs. 4	1	1	-	-
	Simul. 2.37	1	0.6	0.382	0.349

Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 15.2	4	8	-	-
	Simul. 14.18	4.6	6.01	0.993	0.848
2	Obs. 12.4	5	6	-	-
	Simul. 13.5	4.47	4.92	0.881	0.311
3	Obs. 18.6	3.5	9	-	-
	Simul. 11.78	4	5.28	0.727	0.741
4	Obs. 9.2	5.5	6.25	-	-
	Simul. 10.42	3.45	4.5	0.205	0.084
5	Obs. 16.5	3	3.5	-	-
	Simul. 11.88	4.05	5.49	0.646	0.516
6	Obs. 15	3	6	-	-
	Simul. 15.92	4.42	7.15	0.347	0.172
7	Obs. 16	6	10.5	-	-
	Simul. 17.58	3.92	7.88	0.112	0.101
8	Obs. 15	5	9.5	-	-
	Simul. 17.71	4.8	8.51	0.273	0.341
9	Obs. 9	5.5	5	-	-
	Simul. 13.64	3.2	5.91	0.303	0.281
10	Obs. 11	3	5.5	-	-
	Simul. 6.94	2.42	3.08	0.272	0.082
11	Obs. 8.7	2	3.5	-	-
	Simul. 11.76	2.85	4.03	0.628	0.221
12	Obs. 8	3	5	-	-
	Simul. 13.74	4.75	6.69	0.028	0.001

Tabla A.72: Percentiles de las longitudes de racha observada y simulada por *CM sondeos*, Zaragoza (1990-1997).

AIC:	1021.97	BIC:	1041.61
Estad. HL	-	p-valor	-
% variabilidad explicada por modelo			4.71
Autocorrelación orden 1 en residuos			-0.03
% días bien clasificados (0.5)		Anual	77.99
Primavera	Verano	Otoño	Invierno
67.75	84.78	78.77	81.25
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	100
	Húmedo	0	0
%NAS		Anual	0
Primavera	Verano	Otoño	Invierno
0	0	0	0
% días bien clasificados (frec. día)		Anual	62.75
Primavera	Verano	Otoño	Invierno
64.49	47.46	65.57	75.83
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	79.01	0
	Húmedo	23.13	100
%NAS		Anual	23.98
Primavera	Verano	Otoño	Invierno
35.53	16.67	17.05	25.64
Índice relativo de Brier		Anual	4.8
Primavera	Verano	Otoño	Invierno
7.57	-4.56	-2.8	6.53
Días de precipitación observados y estimados por meses			
Coef. correlación	0.9881	Coef. eficiencia	0.5124
Índice de acuerdo	0.7152	% medio error	10.400

Tabla A.73: Medidas de bondad de ajuste de *CM hom*, Zaragoza, periodo de validación (1998-2000).

AIC:	1030.15	BIC:	1074.36
Estad. HL	16.32	p-valor	0.04
% variabilidad explicada por modelo			4.89
Autocorrelación orden 1 en residuos			-0.04
% días bien clasificados (0.5)		Anual	77.29
Primavera	Verano	Otoño	Invierno
67.75	83.7	78.3	80
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	100	80
	Húmedo	0	22.99
%NAS		Anual	8.06
Primavera	Verano	Otoño	Invierno
16.82	0	2.13	2.04
% días bien clasificados (frec. día)		Anual	71.02
Primavera	Verano	Otoño	Invierno
68.12	71.38	68.87	75.83
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	95.99	0
	Húmedo	2.99	100
%NAS		Anual	23.82
Primavera	Verano	Otoño	Invierno
34.81	11.24	16.46	26.58
Índice relativo de Brier		Anual	4.98
Primavera	Verano	Otoño	Invierno
6.93	-2.34	-2.47	5.94
Días de precipitación observados y estimados por meses			
Coef. correlación	0.7346	Coef. eficiencia	0.5221
Índice de acuerdo	0.8051	% medio error	8.084

Tabla A.74: Medidas de bondad de ajuste de *CM est*, Zaragoza, periodo de validación (1998-2000).

AIC:	940.92	BIC:	970.38
Estad. HL	18.3	p-valor	0.02
% variabilidad explicada por modelo			14.41
Autocorrelación orden 1 en residuos			-0.01
% días bien clasificados (0.5)		Anual	80.34
Primavera	Verano	Otoño	Invierno
72.46	84.31	82.08	83.33
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	99.69	83.7
	Húmedo	6.02	44.83
%NAS		Anual	19.26
Primavera	Verano	Otoño	Invierno
20	10.42	22.45	23.08
% días bien clasificados (frec. día)		Anual	66.77
Primavera	Verano	Otoño	Invierno
70.65	62.41	69.34	65
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	77.59	20
	Húmedo	49.62	85.06
%NAS		Anual	29.6
Primavera	Verano	Otoño	Invierno
40.44	18.25	32.29	26.96
Índice relativo de Brier		Anual	14.5
Primavera	Verano	Otoño	Invierno
14.78	1.37	18.89	12.91
Días de precipitación observados y estimados por meses			
Coef. correlación	0.6582	Coef. eficiencia	0.3467
Índice de acuerdo	0.6274	% medio error	4.345

Tabla A.75: Medidas de bondad de ajuste de *CM temp*, Zaragoza, periodo de validación (1998-2000).

AIC:	806.39	BIC:	855.5
Estad. HL	4.66	p-valor	0.79
% variabilidad explicada por modelo			28.21
Autocorrelación orden 1 en residuos			-0.01
% días bien clasificados (0.5)		Anual	83.07
Primavera	Verano	Otoño	Invierno
76.45	88.41	81.6	85.83
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	97.07	88.15
	Húmedo	30.6	51.72
%NAS		Anual	33.59
Primavera	Verano	Otoño	Invierno
35	28.89	33.9	34.62
% días bien clasificados (frec. día)		Anual	76.1
Primavera	Verano	Otoño	Invierno
76.09	74.64	74.53	79.17
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	86.73	31.85
	Húmedo	61.19	88.51
%NAS		Anual	39.85
Primavera	Verano	Otoño	Invierno
50.38	30	37.21	37.5
Índice relativo de Brier		Anual	28.28
Primavera	Verano	Otoño	Invierno
29.28	27.32	19.02	28.87
Días de precipitación observados y estimados por meses			
Coef. correlación	0.8578	Coef. eficiencia	0.6944
Índice de acuerdo	0.8923	% medio error	1.577

Tabla A.76: Medidas de bondad de ajuste de *CM superficie*, Zaragoza, periodo de validación (1998-2000).

AIC:	359.86	BIC:	445.16
Estad. HL	5.92	p-valor	0.66
% variabilidad explicada por modelo			46.46
Autocorrelación orden 1 en residuos			-0.07
% días bien clasificados (0.5)		Anual	87.07
Primavera	Verano	Otoño	Invierno
85	88.81	87.27	87.9
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	97.65	78.46
	Húmedo	47.37	86.36
%NAS		Anual	52.11
Primavera	Verano	Otoño	Invierno
57.81	42.31	53.33	48.65
% días bien clasificados (frec. día)		Anual	83.27
Primavera	Verano	Otoño	Invierno
79.44	90.3	80	82.8
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	88.27	64.62
	Húmedo	71.05	93.18
%NAS		Anual	51.91
Primavera	Verano	Otoño	Invierno
54.32	61.76	42.11	44.9
Índice relativo de Brier		Anual	46.56
Primavera	Verano	Otoño	Invierno
47.63	53.18	43.41	38.88
Días de precipitación observados y estimados por meses			
Coef. correlación	0.8625	Coef. eficiencia	0.7422
Índice de acuerdo	0.9253	% medio error	6.315

Tabla A.77: Medidas de bondad de ajuste de *CM sondeos*, Zaragoza, periodo de validación (1998-2000).

Longitud	Rachas secas		Rachas húmedas	
	Observada	Ajustada	Observada	Ajustada
1	0.222	0.234	0.567	0.572
2	0.111	0.117	0.321	0.236
3	0.096	0.099	0.075	0.106
4	0.089	0.084	0.015	0.047
5	0.059	0.071	0.007	0.021
6	0.074	0.06	0	0.009
7	0.081	0.051	0.007	0.004
8	0.059	0.043	0	0.002
9	0.03	0.037	0.007	0.001
10	0.03	0.031	0	0
11	0.037	0.026	0	0
12	0.015	0.022	0	0
13	0.037	0.019	0	0
14	0.015	0.016	0	0
15	0.015	0.014	0	0
16	0.007	0.012	0	0
17	0.007	0.01	0	0
$\geq 18$	0.015	0.055	0	0
p-valor test $X^2$	0.625		0.009	

Tabla A.78: Distribuciones de las longitudes de racha observada y teórica según *CM hom*, Zaragoza (1998-2000).

Rachas secas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor
1	10.42	6.5	17.33	7	0.981
2	7.67	7.5	5.43	8.75	–
3	4.91	3	4.55	6.5	0.597
4	2.71	2	2.2	3	0.083
5	4.14	3.5	2.74	4.75	0.93
6	7.25	4.5	6.98	8	0.88
7	6.7	6	3.2	1.75	0.08
8	9.18	9	7.17	9	0.388
9	4.73	5	3.44	5	0.351
10	3.58	3	1.93	2.25	0.104
11	6.5	7.5	3.7	4.25	–
12	4.8	3.5	3.65	4.5	0.799
Teórica	5.98	4	5.81	6	–
Rachas húmedas					
Mes	$\bar{x}$	$q_{0.5}$	$\hat{s}$	$q_{0.75} - q_{0.25}$	p-valor
1	1.5	1.5	0.53	1	0.084
2	2	2	0.89	1.5	0.237
3	1.83	1	1.34	1	0.975
4	2.24	2	1.52	2	0.188
5	2.14	2	2.07	1	0.238
6	1.27	1	0.47	0.5	0.268
7	1.27	1	0.47	0.5	0.268
8	1.3	1	0.48	0.75	0.305
9	1.38	1	0.65	1	0.543
10	1.45	1	0.52	1	0.114
11	1.38	1	0.74	0.25	0.31
12	1.64	1	0.81	1	0.96
Teórica	1.77	1	1.2	1	–

Tabla A.79: Distribuciones de las longitudes de racha, observada y teórica según *CM hom*, por meses, Zaragoza (1998-2000).

Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 2	1.5	1	-	-
	Simul. 2.82	1.25	1.06	0.966	0.666
2	Obs. 3	2	1.5	-	-
	Simul. 2.78	1.2	0.76	0.508	0.107
3	Obs. 3.8	1	1	-	-
	Simul. 2.66	1.35	0.88	1	0.848
4	Obs. 3.4	2	2	-	-
	Simul. 3.41	1.48	1.34	0.626	0.213
5	Obs. 2.7	2	1	-	-
	Simul. 4.3	1.6	1.81	0.915	0.871
6	Obs. 2	1	0.5	-	-
	Simul. 2.79	1.2	0.89	0.897	0.356
7	Obs. 2	1	0.5	-	-
	Simul. 3.03	1.18	1.01	0.938	0.367
8	Obs. 2	1	0.75	-	-
	Simul. 2.12	1.2	0.46	1	0.986
9	Obs. 2	1	1	-	-
	Simul. 2.5	1.08	0.9	1	0.642
10	Obs. 2	1	1	-	-
	Simul. 3.07	1.55	1.01	0.807	0.541
11	Obs. 2.3	1	0.25	-	-
	Simul. 3.68	1.45	1.21	0.849	0.217
12	Obs. 3	1	1	-	-
	Simul. 3.53	1.27	1.14	1	0.939

Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 12.8	6.5	7	-	-
	Simul. 16.01	5.55	8.35	0.997	0.962
2	Obs. 13.5	7.5	8.75	-	-
	Simul. 15.74	4.8	7.1	0.86	0.56
3	Obs. 11	3	6.5	-	-
	Simul. 15.8	5.85	7.44	0.844	0.183
4	Obs. 6	2	3	-	-
	Simul. 13.48	5.22	6.18	0.029	0.005
5	Obs. 8	3.5	4.75	-	-
	Simul. 14.9	5	6.19	0.249	0.235
6	Obs. 14.8	4.5	8	-	-
	Simul. 15.3	6.5	6.41	0.859	0.762
7	Obs. 11.2	6	1.75	-	-
	Simul. 18.01	7.98	8.74	0.413	0.611
8	Obs. 15	9	9	-	-
	Simul. 17.4	6.28	8.7	0.581	0.433
9	Obs. 10	5	5	-	-
	Simul. 11.87	5.82	5.9	0.958	0.659
10	Obs. 6.8	3	2.25	-	-
	Simul. 8.76	3.88	4.25	0.889	0.799
11	Obs. 9.6	7.5	4.25	-	-
	Simul. 6.64	2.62	2.96	0.03	0.029
12	Obs. 9.3	3.5	4.5	-	-
	Simul. 9.76	3.02	5.42	0.934	0.489

Tabla A.80: Percentiles de las longitudes de racha observada y simulada por *CM est*, Zaragoza (1998-2000).

## Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	2	1.5	1	—
	Simul.	2.9	1.02	0.79	0.96
2	Obs.	3	2	1.5	—
	Simul.	2.29	1.23	0.62	0.478
3	Obs.	3.8	1	1	—
	Simul.	2.47	1.1	0.7	0.993
4	Obs.	3.4	2	2	—
	Simul.	2.58	1.18	0.85	0.081
5	Obs.	2.7	2	1	—
	Simul.	2.08	1.02	0.46	0.119
6	Obs.	2	1	0.5	—
	Simul.	1.98	1	0.5	1
7	Obs.	2	1	0.5	—
	Simul.	2.19	1.05	0.55	1
8	Obs.	2	1	0.75	—
	Simul.	2.54	1.05	0.49	1
9	Obs.	2	1	1	—
	Simul.	2.35	1.08	0.7	1
10	Obs.	2	1	1	—
	Simul.	2.24	1.12	0.68	0.938
11	Obs.	2.3	1	0.25	—
	Simul.	3.19	1.58	1.15	0.772
12	Obs.	3	1	1	—
	Simul.	2.74	1.25	0.81	1

## Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	12.8	6.5	7	—
	Simul.	10.38	3.9	5.04	0.42
2	Obs.	13.5	7.5	8.75	—
	Simul.	13.92	5.85	6.69	0.901
3	Obs.	11	3	6.5	—
	Simul.	12.59	5.58	5.49	0.536
4	Obs.	6	2	3	—
	Simul.	13.69	5.03	6.34	0.068
5	Obs.	8	3.5	4.75	—
	Simul.	13.07	4.95	6.6	0.341
6	Obs.	14.8	4.5	8	—
	Simul.	12.73	4.97	6.58	0.984
7	Obs.	11.2	6	1.75	—
	Simul.	16.53	5.03	6.76	0.23
8	Obs.	15	9	9	—
	Simul.	12.56	4.72	5.84	0.296
9	Obs.	10	5	5	—
	Simul.	9.73	3.62	4.84	0.967
10	Obs.	6.8	3	2.25	—
	Simul.	11.33	4.45	4.9	0.427
11	Obs.	9.6	7.5	4.25	—
	Simul.	10.56	4.95	5.34	0.126
12	Obs.	9.3	3.5	4.5	—
	Simul.	12.57	4.7	6.36	0.997

Tabla A.81: Percentiles de las longitudes de racha observada y simulada por *CM temp*, Zaragoza (1998-2000).

Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 2	1.5	1	-	-
	Simul. 2.75	1.15	1.12	0.956	0.961
2	Obs. 3	2	1.5	-	-
	Simul. 2.13	1.18	0.59	0.552	0.058
3	Obs. 3.8	1	1	-	-
	Simul. 2.62	1.2	0.92	0.999	0.494
4	Obs. 3.4	2	2	-	-
	Simul. 3	1.42	1.23	0.643	0.172
5	Obs. 2.7	2	1	-	-
	Simul. 2.48	1.2	0.85	0.605	0.174
6	Obs. 2	1	0.5	-	-
	Simul. 1.96	1.05	0.35	1	0.989
7	Obs. 2	1	0.5	-	-
	Simul. 2.28	1.05	0.65	1	0.72
8	Obs. 2	1	0.75	-	-
	Simul. 2.13	1.18	0.66	1	0.611
9	Obs. 2	1	1	-	-
	Simul. 2.48	1.1	0.82	1	0.72
10	Obs. 2	1	1	-	-
	Simul. 2.49	1.12	0.85	0.991	0.742
11	Obs. 2.3	1	0.25	-	-
	Simul. 2.7	1.4	0.98	0.963	0.341
12	Obs. 3	1	1	-	-
	Simul. 2.63	1.23	0.9	1	0.584

Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 12.8	6.5	7	-	-
	Simul. 13.32	4.82	5.55	0.865	0.716
2	Obs. 13.5	7.5	8.75	-	-
	Simul. 24.42	7.1	10.68	0.8	0.875
3	Obs. 11	3	6.5	-	-
	Simul. 12.68	5.15	5.82	0.678	0.297
4	Obs. 6	2	3	-	-
	Simul. 6.91	2.95	2.96	0.568	0.185
5	Obs. 8	3.5	4.75	-	-
	Simul. 12.32	4.7	5.68	0.503	0.306
6	Obs. 14.8	4.5	8	-	-
	Simul. 17.95	6.92	9.57	0.882	0.537
7	Obs. 11.2	6	1.75	-	-
	Simul. 13.92	5.45	6.31	0.574	0.389
8	Obs. 15	9	9	-	-
	Simul. 14.72	5.18	6.6	0.534	0.349
9	Obs. 10	5	5	-	-
	Simul. 8.68	3.55	4.18	0.936	0.744
10	Obs. 6.8	3	2.25	-	-
	Simul. 8.94	3.88	5.14	0.805	0.88
11	Obs. 9.6	7.5	4.25	-	-
	Simul. 11.55	4.62	4.8	0.276	0.319
12	Obs. 9.3	3.5	4.5	-	-
	Simul. 11.32	5.42	5.22	0.998	0.566

Tabla A.82: Percentiles de las longitudes de racha observada y simulada por *CM superficie*, Zaragoza (1998-2000).

## Rachas húmedas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 2	1.5	1	-	-
	Simul. 3.11	1.32	1.15	0.904	0.847
2	Obs. 3	2	1.5	-	-
	Simul. 1.59	1.18	0.28	0.231	0.008
3	Obs. 3.8	1	1	-	-
	Simul. 3.12	1.6	1.21	1	0.614
4	Obs. 3.4	2	2	-	-
	Simul. 2.55	1.25	1.06	0.444	0.056
5	Obs. 2.7	2	1	-	-
	Simul. 3.04	1.6	1.34	0.984	0.83
6	Obs. 2	1	0.5	-	-
	Simul. 2.04	1.15	0.71	1	0.569
7	Obs. 2	1	0.5	-	-
	Simul. 1.93	1.05	0.38	1	0.894
8	Obs. 2	1	0.75	-	-
	Simul. 1.32	1.16	0.13	1	0.526
9	Obs. 2	1	1	-	-
	Simul. 1.1	1	0.02	0.305	0.001
10	Obs. 2	1	1	-	-
	Simul. 3.1	1.72	1.09	0.558	0.573
11	Obs. 2.3	1	0.25	-	-
	Simul. 1.57	1.18	0.26	1	0.885
12	Obs. 3	1	1	-	-
	Simul. 2.07	1.1	0.51	0.92	0.263

## Rachas secas

Mes	$q_{0.9}$	$q_{0.5}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 12.8	6.5	7	-	-
	Simul. 15.36	3.35	5.22	0.335	0.391
2	Obs. 13.5	7.5	8.75	-	-
	Simul. 18.85	6.82	7.2	0.847	0.913
3	Obs. 11	3	6.5	-	-
	Simul. 11.97	3.25	5.65	0.992	0.688
4	Obs. 6	2	3	-	-
	Simul. 5.12	2.35	2.29	0.507	0.382
5	Obs. 8	3.5	4.75	-	-
	Simul. 7.58	3.48	2.91	0.898	0.883
6	Obs. 14.8	4.5	8	-	-
	Simul. 15.13	8.28	6.22	0.271	0.402
7	Obs. 11.2	6	1.75	-	-
	Simul. 9.38	4.15	2.86	0.078	0.04
8	Obs. 15	9	9	-	-
	Simul. 12.34	8.35	5.14	0.885	0.528
9	Obs. 10	5	5	-	-
	Simul. 8.04	3.4	3.78	0.497	0.468
10	Obs. 6.8	3	2.25	-	-
	Simul. 4.39	2.72	1.76	0.113	0.024
11	Obs. 9.6	7.5	4.25	-	-
	Simul. 13.82	8.75	5.05	0.632	0.759
12	Obs. 9.3	3.5	4.5	-	-
	Simul. 10.08	5.78	3.18	0.966	0.37

Tabla A.83: Percentiles de las longitudes de racha observada y simulada por *CM sondeos*, Zaragoza (1998-2000).

## A.2 Modelos de cantidad

En este apéndice se muestran las tablas con los resultados de los ajustes, de crítica y validación de los modelos con distribución Gamma para la cantidad en días de precipitación positiva registrada en Reinoso, Tortosa, Agoncillo y Zaragoza.

### A.2.1 Reinoso

Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	4.287	0.1588	26.990
$Y_{t-1}$	0.4766	0.1289	3.697
$Y_{t-2}$	0.1245	0.06186	2.012
$Y_{t-1} : Y_{t-2}$	-0.1638	0.07397	-2.214
$Q_{t-1}$	0.005503	7.488e-4	7.350
$Q_{t-1}^2$	-1.093e-5	3.136e-6	-3.484
$Q_{t-1}^3$	8.004e-9	3.137e-9	2.551
$S1$	0.06249	0.04102	1.523
$C1$	0.01476	0.04709	0.3133
$Y_{t-1} : S1$	-0.1546	0.05304	-2.916
$Y_{t-1} : C1$	0.01396	0.06497	0.2148
$S2$	-0.131	0.04079	-3.212
$C2$	0.04431	0.03971	1.116
$Y_{t-1} : S2$	0.1264	0.04954	2.552
$Y_{t-1} : C2$	-0.02933	0.04902	-0.5982
$TDIF_t$	-0.02047	0.004015	-5.098
$Y_{t-1} : TDIF_t$	-0.003008	0.001144	-2.630
$TDIF_t^2$	1.450e-4	3.842e-5	3.774
$TDIF_t^3$	-3.420e-7	1.156e-7	-2.957
$TDIF_{t-1}$	0.001968	4.730e-4	4.160
$TMIN_t^2$	1.438e-5	4.939e-6	2.911
$Y_{t-1} : TMIN_t$	-0.003073	6.952e-4	-4.420
Parámetro de dispersión: 1.974			

Tabla A.84: Modelo para la cantidad de precipitación positiva en Reinoso (1912-1959).

		Deviance	Gr. lib.	
Modelo nulo		15117.25	7627	
Modelo ajustado		13487.98	7605	
AIC: 75662.45		BIC: 75815.12		
% variabilidad explicada por modelo			14.83	
Primavera	Verano	Otoño	Invierno	
12.92	0.42	9.93	21.17	
Autocorrelación orden 1 en residuos			0	
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.953	Coef. eficiencia	0.8982	
Índice de acuerdo	0.9696	% medio error	0.6688	
Cantidad media de precipitación observada y ajustada por años				
Coef. correlación	0.7657	Coef. eficiencia	0.4504	
Índice de acuerdo	0.6988	% medio error	1.467	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25}]$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
0.9178	18.990	55.260	15.730	9.099
% días clasificados en los intervalos, si el día anterior seco				
0.3097	20.090	55.710	14.360	9.524
% días clasificados en los intervalos, si el día anterior llovió				
1.229	18.420	55.040	16.440	8.882
% días ( $q_{0.10}, q_{0.90}$ )	Primavera	Verano	Otoño	Invierno
	91.100	88.950	89.880	89.550

Tabla A.85: Medidas de bondad de ajuste para el modelo de cantidad en Reinosa (1912-1959).

Mes		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	306.35	32	88.75	–	–
	Simul.	294.12	29.13	80.51	0	0.004
2	Obs.	302.5	30	81.5	–	–
	Simul.	275.7	27.44	74.91	0	0
3	Obs.	226	26	67	–	–
	Simul.	227.29	23.78	62.63	0	0
4	Obs.	206.25	26	63	–	–
	Simul.	212.73	23.31	63.16	0	0.001
5	Obs.	172.2	24	56	–	–
	Simul.	205.48	23.38	61.58	0	0.227
6	Obs.	205.4	21	65	–	–
	Simul.	197.62	22.38	61.53	0	0.325
7	Obs.	251.1	19.5	62.5	–	–
	Simul.	190.91	20.92	59.65	0.001	0.552
8	Obs.	154.15	14	43.25	–	–
	Simul.	176.32	20.04	54.4	0	0.094
9	Obs.	252	17	57	–	–
	Simul.	211.08	22.52	62.72	0	0.474
10	Obs.	279.8	30	73	–	–
	Simul.	255.94	25.5	72.81	0	0.005
11	Obs.	266.55	25.5	76	–	–
	Simul.	271.43	28.95	78	0	0.85
12	Obs.	287.5	31	84	–	–
	Simul.	309.29	31.04	86.52	0	0.02

Tabla A.86: Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Reinosa (1912-1959).

AIC: 23566.98		BIC: 23694.73		
% variabilidad explicada por modelo			7.19	
Primavera	Verano	Otoño	Invierno	
8.02	0	8.82	6.2	
Autocorrelación orden 1 en residuos			-0.01	
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.8409	Coef. eficiencia	0.3729	
Índice de acuerdo	0.8486	% medio error	9.912	
Cantidad media de precipitación observada y ajustada por años				
Coef. correlación	0.4942	Coef. eficiencia	-0.3471	
Índice de acuerdo	0.515	% medio error	12.610	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
1.058	23.070	54.230	13.060	8.584
% días clasificados en los intervalos, si el día anterior fue seco				
0.119	26.550	53.100	10.830	9.405
% días clasificados en los intervalos, si el día anterior llovió				
1.545	21.260	54.820	14.220	8.158
% días ( $q_{0.10}, q_{0.90}$ )	Primavera	Verano	Otoño	Invierno
	92.690	87.650	88.740	90.540

Tabla A.87: Medidas de bondad de ajuste para el modelo de cantidad en Reinos, periodo de validación (1960-1975).

Mes		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	250.2	19	54	–	–
	Simul.	267.9	29.58	75.79	0.018	0.127
2	Obs.	251.95	23.5	61	–	–
	Simul.	266	27.35	72.08	0.009	0.778
3	Obs.	176	25	59	–	–
	Simul.	222.64	23.25	63.66	0.001	0.284
4	Obs.	151.4	21	48	–	–
	Simul.	198.26	22.48	59.11	0.003	0.868
5	Obs.	178.3	21	51.75	–	–
	Simul.	205.1	22.61	59.26	0.016	0.797
6	Obs.	203	18	54	–	–
	Simul.	211.53	23.12	62.17	0.074	0.699
7	Obs.	279	10	56	–	–
	Simul.	194.29	20.89	54.59	0.073	0.4
8	Obs.	170.95	18	44.5	–	–
	Simul.	184.86	21.64	56.92	0.171	0.452
9	Obs.	238	26	64	–	–
	Simul.	207.06	21.77	60.89	0.035	0.145
10	Obs.	322.05	21.5	63.5	–	–
	Simul.	246.82	25.84	69.36	0.022	0.808
11	Obs.	255.1	25.5	83.5	–	–
	Simul.	271.43	29.43	81.31	0.013	0.876
12	Obs.	289	26.5	83	–	–
	Simul.	302.29	33.24	87.15	0.026	0.859

Tabla A.88: Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Reínoša, periodo de validación (1960-1975).

## A.2.2 Tortosa

Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	5.924	0.2033	29.140
$Q_{t-1}$	0.002641	4.958e-4	5.326
$Q_{t-1}^2$	-2.044e-6	5.460e-7	-3.744
$S1$	-0.4841	0.06312	-7.669
$C1$	-0.6012	0.09846	-6.106
$S2$	-0.02211	0.04518	-0.4893
$C2$	-0.1913	0.04298	-4.450
$S3$	0.1066	0.04289	2.484
$C3$	0.03888	0.04289	0.9063
$S4$	-0.1009	0.04244	-2.378
$C4$	-0.02716	0.04304	-0.6311
$TDIF_t$	-0.01602	0.001027	-15.600
$TMIN_t$	-0.008931	0.001592	-5.611
$TMIN_{t-1}$	0.003489	0.001461	2.389
Parámetro de dispersión: 2.832			

Tabla A.89: Modelo para la cantidad de precipitación diaria, Tortosa (1942-1981).

		Deviance	Gr. lib.	
Modelo nulo		8025.1	3164	
Modelo ajustado		6659.46	3150	
AIC:	24415.38	BIC:	24500.22	
% variabilidad explicada			16.47	
Primavera	Verano	Otoño	Invierno	
16.46	6.67	15.82	15.52	
Autocorrelación orden 1 en residuos			0.03	
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.9708	Coef. eficiencia	0.934	
Índice de acuerdo	0.9812	% medio error	1.185	
Cantidad media de precipitación observada y ajustada por años				
Coef. correlación	0.546	Coef. eficiencia	0.2867	
Índice de acuerdo	0.696	% medio error	4.660	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
0.000	10.240	66.530	14.250	8.976
% días clasificados en los intervalos, si el día anterior fue seco				
0.000	10.450	67.680	13.380	8.496
% días clasificados en los intervalos, si el día anterior llovió				
0.000	9.986	65.120	15.330	9.564
% días ( $q_{0.10}, q_{0.90}$ )	Primavera	Verano	Otoño	Invierno
	91.790	91.330	90.840	90.100

Tabla A.90: Medidas de bondad de ajuste para el modelo de cantidad, Tortosa (1942-1981).

Mes		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	194.6	17	45	–	–
	Simul.	200.98	11.61	47.52	0	0
2	Obs.	194.8	17	44	–	–
	Simul.	201.6	11.52	45.85	0	0
3	Obs.	193	22	55	–	–
	Simul.	227.72	13.02	52.03	0	0
4	Obs.	298.95	25	62	–	–
	Simul.	285.76	14.91	59.46	0	0
5	Obs.	326.9	26	68.5	–	–
	Simul.	314.73	18.77	73.25	0	0
6	Obs.	265.85	20.5	62.75	–	–
	Simul.	321.75	17.38	66.84	0	0.03
7	Obs.	198.25	11	30.5	–	–
	Simul.	193.1	13.94	49.71	0	0.679
8	Obs.	251.25	19	75	–	–
	Simul.	320.4	20.83	76.35	0	0.108
9	Obs.	640	33.5	136.75	–	–
	Simul.	512.8	31.15	117.23	0	0.022
10	Obs.	509	28	100	–	–
	Simul.	479.78	25.86	106.38	0	0.032
11	Obs.	279.3	23	62	–	–
	Simul.	325.14	19.73	80.69	0	0.095
12	Obs.	346	20	53.5	–	–
	Simul.	267.25	16.28	64.68	0	0.002

Tabla A.91: Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Tortosa (1942-1981).

AIC: 5499.29		BIC: 5563.46		
% variabilidad explicada por modelo			8.01	
Primavera	Verano	Otoño	Invierno	
6.29	0.31	5.55	0.69	
Autocorrelación orden 1 en residuos			0.01	
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.7822	Coef. eficiencia	0.5918	
Índice de acuerdo	0.8591	% medio error	10.980	
Cantidad media de precipitación observada y ajustada por años				
Coef. correlación	0.2799	Coef. eficiencia	-0.02284	
Índice de acuerdo	0.4447	% medio error	11.280	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
0.000	10.650	66.530	13.690	9.129
% días clasificados en los intervalos, si el día anterior fue seco				
0.000	9.474	68.680	13.950	7.895
% días clasificados en los intervalos, si el día anterior llovió				
0.000	11.950	64.140	13.410	10.500
% días ( $q_{0.10}, q_{0.90}$ )	Primavera	Verano	Otoño	Invierno
	92.200	92.750	89.360	89.390

Tabla A.92: Medidas de bondad de ajuste para el modelo de cantidad en Tortosa, periodo de validación (1982-1991).

Mes		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	235.3	22	57.5	–	–
	Simul.	221.62	15.08	51.55	0.015	0.048
2	Obs.	133	12	35.5	–	–
	Simul.	202.96	10.66	43.87	0	0.167
3	Obs.	222.7	14	55.5	–	–
	Simul.	196.3	16.22	53.58	0.013	0.359
4	Obs.	191	10	39.75	–	–
	Simul.	237.97	15.26	59.21	0.006	0.892
5	Obs.	195.2	23	56.75	–	–
	Simul.	280.28	17.12	68.45	0.009	0.332
6	Obs.	155.55	13	33.5	–	–
	Simul.	235.22	16.84	57.27	0.012	0.689
7	Obs.	181.6	15	30	–	–
	Simul.	167.06	11.3	43.34	0.033	0.186
8	Obs.	337.5	31	79.5	–	–
	Simul.	351.65	21.3	74.47	0.079	0.138
9	Obs.	283.1	26	85.25	–	–
	Simul.	432.23	32.21	112.8	0.148	0.997
10	Obs.	411.35	36.5	133.5	–	–
	Simul.	404.03	27.44	105.61	0.031	0.037
11	Obs.	528.4	29.5	129	–	–
	Simul.	354.5	23.96	87.65	0.012	0.024
12	Obs.	208.8	19	77	–	–
	Simul.	287.18	16.85	61.86	0.092	0.213

Tabla A.93: Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Tortosa, periodo de validación (1982-1991).

## A.2.3 Agoncillo

Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-1437.000	370.400	-3.880
$Q_{t-1}$	0.00267	7.880e-4	3.389
$S1$	-0.02508	0.06387	-0.3926
$C1$	-0.1742	0.1018	-1.711
$S2$	-0.08589	0.0541	-1.588
$C2$	0.138	0.04978	2.771
$S3$	-0.04412	0.048	-0.9193
$C3$	-0.06058	0.05032	-1.204
$S4$	0.01608	0.049	0.3281
$C4$	0.1069	0.04777	2.238
$TDIF_t$	-0.006406	0.00123	-5.207
$TDIF_{t-1}$	0.005896	0.001121	5.261
$TMIN_t$	-0.004918	0.001643	-2.994
$TMIN_{t-1}$	0.006013	0.001571	3.828
$P00_t$	0.006425	0.001617	3.974
$P07_t$	-0.004607	0.002113	-2.180
$P18_t$	0.2858	0.07324	3.902
$P18_t^2$	-1.435e-5	3.617e-6	-3.968
Parámetro de dispersión: 1.798			

Tabla A.94: Modelo para la cantidad de precipitación diaria, Agoncillo (1978-1992).

		Deviance	Gr. lib.	
Modelo nulo		2921.55	1634	
Modelo ajustado		2529.75	1616	
AIC:	14460.88	BIC:	14558.06	
% variabilidad explicada por modelo			12.24	
Primavera	Verano	Otoño	Invierno	
10.23	9.08	5.94	12.72	
Autocorrelación orden 1 en residuos			-0.05	
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.9296	Coef. eficiencia	0.8632	
Índice de acuerdo	0.9607	% medio error	1.465	
Cantidad media de precipitación observada y ajustada por años				
Coef. correlación	0.5279	Coef. eficiencia	0.2627	
Índice de acuerdo	0.6008	% medio error	2.452	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
0.6732	18.360	56.430	15.420	9.119
% días clasificados en los intervalos, si el día anterior fue seco				
0.7853	18.320	56.540	15.180	9.162
% días clasificados en los intervalos, si el día anterior llovió				
0.5747	18.390	56.320	15.630	9.080
% días ( $q_{0.10}, q_{0.90}$ )	Primavera	Verano	Otoño	Invierno
	89.920	87.450	92.730	90.040

Tabla A.95: Medidas de bondad de ajuste para el modelo de cantidad, Agoncillo (1978-1992).

Mes		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	82.5	8	30.75	–	–
	Simul.	96.84	10.13	29.22	0.001	0.426
2	Obs.	80	13	28.5	–	–
	Simul.	85.03	10.31	26.4	0.004	0.003
3	Obs.	121	9	26	–	–
	Simul.	114.26	14.4	32.61	0.027	0.479
4	Obs.	169.65	16.5	41.75	–	–
	Simul.	132.6	16.43	41.53	0.023	0.219
5	Obs.	140.5	18	38.5	–	–
	Simul.	128.92	17.71	42.61	0.022	0.597
6	Obs.	282.15	25	74.5	–	–
	Simul.	202.98	24.15	64.9	0.312	0.403
7	Obs.	174.5	20	54.5	–	–
	Simul.	211.77	24.4	67.94	0.355	0.511
8	Obs.	129.9	17	58.5	–	–
	Simul.	125.68	18.46	41.68	0.055	0.276
9	Obs.	109.3	12	24.75	–	–
	Simul.	115.53	15.45	38.53	0.197	0.552
10	Obs.	124.2	24	49.5	–	–
	Simul.	126.68	16.21	39.28	0.045	0.021
11	Obs.	99.25	14	33.25	–	–
	Simul.	109.16	12.66	34.68	0.01	0.19
12	Obs.	111.2	17	34	–	–
	Simul.	120.66	13.71	35.19	0.025	0.172

Tabla A.96: Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Agoncillo (1978-1992).

AIC:		5109.89		BIC:		5187.89			
% variabilidad explicada por modelo						10.53			
Primavera		Verano		Otoño		Invierno			
14.25		1.16		11.74		13.43			
Autocorrelación orden 1 en residuos						0.1			
Cantidad media de precipitación observada y ajustada por meses									
Coef. correlación		0.6535		Coef. eficiencia		-0.0889			
Índice de acuerdo		0.7849		% medio error		4.601			
Cantidad media de precipitación observada y ajustada por años									
Coef. correlación		0.8002		Coef. eficiencia		0.1813			
Índice de acuerdo		0.5907		% medio error		6.226			
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada									
$< q_{0.10}$		$[q_{0.10}, q_{0.25})$		$[q_{0.25}, q_{0.75}]$		$(q_{0.75}, q_{0.90}]$		$> q_{0.90}$	
1.954		21.670		50.980		12.970		12.430	
% días clasificados en los intervalos, si el día anterior fue seco									
3.077		22.310		50.770		10.770		13.080	
% días clasificados en los intervalos, si el día anterior llovió									
0.9901		21.120		51.160		14.850		11.880	
% días ( $q_{0.10}, q_{0.90}$ )		Primavera		Verano		Otoño		Invierno	
		87.680		85.710		86.180		83.330	

Tabla A.97: Medidas de bondad de ajuste para el modelo de cantidad en Agoncillo, periodo de validación (1993-1997).

Mes		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	132.75	15.5	37.25	–	–
	Simul.	102.76	12.37	29.43	0.068	0.05
2	Obs.	93.6	12.5	26.5	–	–
	Simul.	70.9	9.55	22.8	0.147	0.143
3	Obs.	104	13.5	63	–	–
	Simul.	103.82	15.19	37	0.726	0.588
4	Obs.	151.05	18	40	–	–
	Simul.	112.19	16.38	37.87	0.425	0.624
5	Obs.	162.3	22	32.5	–	–
	Simul.	137.7	18.74	44.23	0.442	0.799
6	Obs.	186.7	11	46.75	–	–
	Simul.	216.65	27.48	66.9	0.166	0.248
7	Obs.	274.85	27.5	45.75	–	–
	Simul.	228.72	31.83	77.76	0.398	0.51
8	Obs.	131	17	54	–	–
	Simul.	122.15	18.93	39.78	0.869	0.572
9	Obs.	148.3	10.5	34	–	–
	Simul.	124.91	14.83	41.99	0.522	0.594
10	Obs.	124.35	11	24.75	–	–
	Simul.	126.69	15.87	38.07	0.081	0.146
11	Obs.	123.05	27	64.5	–	–
	Simul.	112.81	14.21	37.95	0.11	0.056
12	Obs.	257.95	18	52.25	–	–
	Simul.	122.46	14.69	36.75	0.173	0.049

Tabla A.98: Percentiles de las cantidades observadas y simuladas por el modelo de cantidad, Agoncillo, periodo de validación (1993-1997).

### A.2.4 Zaragoza

Término	Coeficiente	Error std.	Estadístico $t$
$\beta_0$	-2073.000	637.600	-3.251
$Y_{t-1}$	0.2784	0.09864	2.823
$S1$	-0.06138	0.08663	-0.7085
$C1$	-0.7604	0.1429	-5.322
$S2$	0.1476	0.06855	2.154
$C2$	-0.02476	0.07055	-0.3509
$S3$	0.09944	0.06688	1.487
$C3$	0.1568	0.06609	2.372
$T00_t$	0.005034	0.001877	2.682
$T18_t$	-0.007607	0.00203	-3.748
$TDIF_t$	-0.01301	0.00604	-2.154
$TDIF_t^2$	8.314e-5	3.133e-5	2.654
$P18_t$	-0.005977	9.290e-4	-6.434
$P13_{t-1}$	0.4317	0.1295	3.332
$P13_{t-1}^2$	-2.183e-5	6.597e-6	-3.310
$H13_t$	0.01248	0.004217	2.960
$H18_t$	0.02098	0.004117	5.094
Parámetro de dispersión: 1.257			

Tabla A.99: Modelo para la cantidad de precipitación diaria con información de superficie, Zaragoza (1990-1997).

		Deviance	Gr. lib.	
Modelo nulo		1118.13	615	
Modelo ajustado		754.89	598	
AIC:	6646.35	BIC:	6721.51	
% variabilidad explicada por modelo			36.43	
Primavera	Verano	Otoño	Invierno	
40.7	37.58	29.61	41.7	
Autocorrelación orden 1 en residuos			0.03	
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.8959	Coef. eficiencia	0.7663	
Índice de acuerdo	0.9154	% medio error	3.673	
Cantidad media de precipitación observada y ajustada por años				
Coef. correlación	0.8909	Coef. eficiencia	0.7324	
Índice de acuerdo	0.8973	% medio error	1.032	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
5.854	16.590	52.680	15.610	9.268
% días clasificados en los intervalos, si el día anterior fue seco				
6.916	17.870	49.570	15.850	9.798
% días clasificados en los intervalos, si el día anterior llovió				
4.478	14.930	56.720	15.300	8.582
% días ( $q_{0.10}, q_{0.90}$ )	Primavera	Verano	Otoño	Invierno
	86.030	86.730	85.260	82.390

Tabla A.100: Medidas de bondad de ajuste para el modelo de cantidad con información de superficie, Zaragoza (1990-1997).

AIC:		2194.37		BIC:		2251.59			
% variabilidad explicada por modelo						21.08			
Primavera		Verano		Otoño		Invierno			
46.19		0		0		0			
Autocorrelacion orden 1 en residuos						0.15			
Cantidad media de precipitación observada y ajustada por meses									
Coef. correlación		0.4684		Coef. eficiencia		-2.540			
Índice de acuerdo		0.5398		% medio error		19.710			
Cantidad media de precipitación observada y ajustada por años									
Coef. correlación		0.8594		Coef. eficiencia		0.09683			
Índice de acuerdo		0.7709		% medio error		23.860			
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada									
$< q_{0.10}$		$[q_{0.10}, q_{0.25})$		$[q_{0.25}, q_{0.75}]$		$(q_{0.75}, q_{0.90}]$		$> q_{0.90}$	
7.009		22.900		50.000		11.210		8.879	
% días clasificados en los intervalos, si el día anterior fue seco									
5.512		22.050		53.540		11.020		7.874	
% días clasificados en los intervalos, si el día anterior llovió									
9.195		24.140		44.830		11.490		10.340	
% días ( $q_{0.10}, q_{0.90}$ )		Primavera		Verano		Otoño		Invierno	
		84.270		76.320		90.480		84.440	

Tabla A.101: Medidas de bondad de ajuste para el modelo de cantidad con información de superficie, Zaragoza, periodo de validación (1998-2000).

Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-2260.000	761.400	-2.968
$Y_{t-1}$	0.2918	0.107	2.727
$S1$	-0.07908	0.09338	-0.8469
$C1$	-0.9522	0.1523	-6.251
$S2$	0.1794	0.07521	2.385
$C2$	0.0348	0.07254	0.4797
$T18_t$	-0.00629	0.002	-3.144
$TDIF_t$	-0.0168	0.006173	-2.721
$TDIF_t^2$	7.178e-5	3.245e-5	2.212
$P18_t$	-0.005819	9.855e-4	-5.904
$P13_{t-1}$	0.4697	0.1548	3.034
$P13_{t-1}^2$	-2.377e-5	7.886e-6	-3.014
$H18_t$	0.0218	0.003928	5.551
$z.T700.00_t$	0.005694	0.001882	3.026
$R700.12_t$	-0.002162	8.492e-4	-2.546
$vVSUP.00_t$	0.04754	0.01994	2.384
$dVSUP.00.NW_t : vVSUP.00_t$	-0.06204	0.02429	-2.554
$dVSUP.00.NW_t$	0.4374	0.1816	2.408
$dVSUP.00.SW_t$	-1.094	0.4147	-2.638
$dVSUP.00.SW_t : dV500.00.cos_t$	-0.6109	0.3933	-1.553
$dVSUP.00.SW_t : dV500.00.sen_t$	-1.061	0.4365	-2.432
Parámetro de dispersión: 1.159			

Tabla A.102: Modelo para la cantidad de precipitación diaria con información del radiosondeo, Zaragoza (1990-1997).

		Deviance	Gr. lib.	
Modelo nulo		916.35	518	
Modelo ajustado		594.22	497	
AIC:	5856.48	BIC:	5945.73	
% variabilidad explicada por modelo			40.24	
Primavera	Verano	Otoño	Invierno	
50.92	36.69	33.77	34.61	
Autocorrelación orden 1 en residuos			-0.01	
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.8197	Coef. eficiencia	0.6684	
Índice de acuerdo	0.8862	% medio error	4.587	
Cantidad media de precipitación observada y ajustada por años				
Coef. correlación	0.8698	Coef. eficiencia	0.7002	
Índice de acuerdo	0.8827	% medio error	5.085	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
7.529	15.830	51.350	15.830	9.459
% días clasificados en los intervalos, si el día anterior fue seco				
8.163	16.670	48.300	16.670	10.200
% días clasificados en los intervalos, si el día anterior llovió				
6.696	14.730	55.360	14.730	8.482
% días ( $q_{0.10}, q_{0.90}$ )	Primavera	Verano	Otoño	Invierno
	81.360	84.160	86.000	80.540

Tabla A.103: Medidas de bondad de ajuste del modelo de cantidad con información del radiosondeo, Zaragoza (1990-1997).

Mes		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	110.2	20	53.75	–	–
	Simul.	153.58	14.6	33.79	0.207	0.386
2	Obs.	102.4	20	35.5	–	–
	Simul.	132.73	13.65	31.03	0.659	0.529
3	Obs.	51	15.5	22.75	–	–
	Simul.	114.52	15.37	37.17	0.562	0.944
4	Obs.	221.8	22	61.5	–	–
	Simul.	181.64	21.43	43.62	0.631	0.558
5	Obs.	163.4	27	45	–	–
	Simul.	180.93	21.49	41.06	0.319	0.246
6	Obs.	167.2	23	29.5	–	–
	Simul.	184.56	22.87	44.12	0.641	0.589
7	Obs.	99.7	16	33	–	–
	Simul.	119.68	14.71	33.02	0.929	0.676
8	Obs.	112.95	13	25.75	–	–
	Simul.	93.95	14	26.17	0.879	0.975
9	Obs.	165.5	12	39	–	–
	Simul.	125.94	16.92	32.88	0.567	0.726
10	Obs.	150	24	36	–	–
	Simul.	108.01	16.28	32.64	0.385	0.159
11	Obs.	100.6	11.5	34.75	–	–
	Simul.	93	14.44	27.93	0.836	0.964
12	Obs.	137.75	16	27.5	–	–
	Simul.	125.08	13.95	30.97	0.784	0.944

Tabla A.104: Percentiles de las cantidades observadas y simuladas por el modelo de cantidad con información del radiosondeo, Zaragoza (1990-1997).

AIC:		1571.13		BIC:		1633.93			
% variabilidad explicada por modelo						20.82			
Primavera		Verano		Otoño		Invierno			
28.13		0		8.22		5.47			
Autocorrelación orden 1 en residuos						0.03			
Cantidad media de precipitación observada y ajustada por meses									
Coef. correlación		0.5759		Coef. eficiencia		-2.665			
Índice de acuerdo		0.5709		% medio error		29.430			
Cantidad media de precipitación observada y ajustada por años									
Coef. correlación		0.728		Coef. eficiencia		0.2497			
Índice de acuerdo		0.7252		% medio error		23.440			
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada									
$< q_{0.10}$		$[q_{0.10}, q_{0.25})$		$[q_{0.25}, q_{0.75}]$		$(q_{0.75}, q_{0.90}]$		$> q_{0.90}$	
8.844		23.810		49.660		10.200		7.483	
% días clasificados en los intervalos, si el día anterior fue seco									
9.677		20.430		55.910		8.602		5.376	
% días clasificados en los intervalos, si el día anterior llovió									
7.407		29.630		38.890		12.960		11.110	
% días ( $q_{0.10}, q_{0.90}$ )		Primavera		Verano		Otoño		Invierno	
		77.940		85.190		100.000		86.110	

Tabla A.105: Medidas de bondad de ajuste para el modelo de cantidad con información del radiosondeo, Zaragoza, periodo de validación (1998-2000).

Mes		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs.	84.75	8.5	39.25	–	–
	Simul.	111.05	18.78	33.05	0.456	0.399
2	Obs.	97	3.5	20.75	–	–
	Simul.	112.06	12.68	23.88	0.161	0.316
3	Obs.	104.5	16	34.75	–	–
	Simul.	114.03	18.02	36.71	0.709	0.771
4	Obs.	143.85	9	21.25	–	–
	Simul.	148.66	14.75	33.82	0.377	0.471
5	Obs.	214.05	11.5	36	–	–
	Simul.	119.21	19.08	37.23	0.643	0.393
6	Obs.	81	40	52.5	–	–
	Simul.	161.33	28.19	49.57	0.684	0.649
7	Obs.	92.5	13	11.5	–	–
	Simul.	90.75	20.03	32.6	0.376	0.568
8	Obs.	22.6	6	14	–	–
	Simul.	37.55	11.23	15.24	0.975	0.679
9	Obs.	57	39	27	–	–
	Simul.	227.77	72.71	115.31	0.699	0.488
10	Obs.	57	31	42.5	–	–
	Simul.	87.3	15.08	31.34	0.57	0.831
11	Obs.	107.25	5	8.5	–	–
	Simul.	68.71	15.39	21.62	0.41	0.236
12	Obs.	65.65	10.5	15.25	–	–
	Simul.	69.51	11.72	23.59	0.944	0.765

Tabla A.106: Percentiles de las cantidades observadas y simuladas por el modelo de cantidad con información del radiosondeo, Zaragoza, periodo de validación (1998-2000).



# Apéndice B

## Tablas de los modelos para la previsión en Zaragoza

En este apéndice se muestran las tablas con los resultados de los ajustes, de crítica y validación de los modelos para la previsión a corto plazo en el aeropuerto de Zaragoza. También contiene las tablas con los resultados de la comparación con la previsión generada por el modelo HIRLAM.

### B.1 Tablas de los modelos para la previsión estadística

Término	Coficiente	Error std.	Estad. $t$
$\beta_0$	-2014.000	910.700	-2.211
$S1$	-0.05502	0.08083	-0.6806
$C1$	0.5903	0.09157	6.446
$S2$	-0.2363	0.07911	-2.987
$C2$	0.0927	0.08127	1.141
$P18_{t-1}$	0.419	0.1853	2.262
$P18^2_{t-1}$	-2.180e-5	9.422e-6	-2.314
$z.\Delta P.18.13_{t-1}$	-0.03243	0.004802	-6.754
$z.H18_{t-1}$	0.01448	0.004583	3.159
$vV SUP.12_{t-1}$	-0.03733	0.01189	-3.139
$z.R700.12_{t-1}$	-0.002792	6.741e-4	-4.141
$z.A85/50.12_{t-1}$	0.003901	0.001308	2.983
$dV SUP.12.calma_{t-1} : (P00_{t-1} - P00_{t-2})$	0.0203	0.007767	2.613
$dV SUP.12.calma_{t-1} : dV500.12.sen_{t-1}$	-0.4533	0.4106	-1.104
$dV SUP.12.calma_{t-1} : dV500.12.cos_{t-1}$	-1.223	0.511	-2.394
$dV SUP.12.calma_{t-1} : dV500.12.sen2_{t-1}$	-0.8239	0.3998	-2.061
$dV SUP.12.calma_{t-1} : dV500.12.cos2_{t-1}$	-0.310	0.4712	-0.6579
$dV SUP.12.norte_{t-1} : vV500.12_{t-1}$	-0.03628	0.01611	-2.251
$dV SUP.12.norte_{t-1} : A85/50.12_{t-1}$	-3.796e-4	1.070e-4	-3.548
$dV SUP.12.este_{t-1} : z.T18_{t-1}$	-0.009387	0.00312	-3.009
$dV SUP.12.este_{t-1} : z.H07_{t-1}$	0.02975	0.0112	2.656
$dV SUP.12.este_{t-1} : z.\Delta P.7.0_{t-1}$	0.02144	0.006919	3.099
$dV SUP.12.este_{t-1} : A85/50.12_{t-1}$	-1.278e-4	5.699e-5	-2.243
$dV SUP.12.este_{t-1} : dV500.12.sen_{t-1}$	-0.2985	0.1864	-1.601
$dV SUP.12.este_{t-1} : dV500.12.cos_{t-1}$	-0.5595	0.1986	-2.817
$dV SUP.12.SW_{t-1} : dV500.12.sen_{t-1}$	0.5115	0.4906	1.042
$dV SUP.12.SW_{t-1} : dV500.12.cos_{t-1}$	-2.803	0.7986	-3.511
$dV SUP.12.NW_{t-1} : z.\Delta P.18.13^2_{t-1}$	4.009e-4	1.599e-4	2.507
$dV SUP.12.NW_{t-1} : vV500.12_{t-1}$	0.0144	0.00447	3.221

Tabla B.1: Modelo de previsión de ocurrencia a las 18h del día previo.

		Deviance	Gr. lib.
Modelo nulo		2556.55	2362
Modelo ajustado		2048.83	2333
AIC:	2106.83	BIC:	2274.09
Estad. HL	5.4	p-valor	0.71
% variabilidad explicada por modelo		21.63	
Autocorrelación orden 1 en residuos		0.06	
% días bien clasificados (0.5)		Anual	80.61
Primavera	Verano	Otoño	Invierno
81.83	83.36	76.32	81.05
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	97.41	80
	Húmedo	20.33	52.89
%NAS		Anual	29.32
Primavera	Verano	Otoño	Invierno
29.53	12.5	27.78	40.74
% días bien clasificados ( $\leq$ frec. día)		Anual	69.9
Primavera	Verano	Otoño	Invierno
75.78	64.52	68.38	71.07
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	75.81	37.1
	Húmedo	60.98	86.36
%NAS		Anual	35.71
Primavera	Verano	Otoño	Invierno
38.86	27.18	37.79	39.58
Índice relativo de Brier		Anual	21.67
Primavera	Verano	Otoño	Invierno
27	13.45	16.98	26.01
Días de precipitación observados y predichos por meses			
Coef. correlación	0.9192	Coef. eficiencia	0.843
Índice de acuerdo	0.9535	% medio error	1.696

Tabla B.2: Medidas de bondad de ajuste del modelo de previsión de ocurrencia para todo el año (1990-1997).

AIC: 703.5		BIC: 834.29	
Estad. HL 10.82		p-valor 0.21	
% variabilidad explicada por modelo		15.13	
Autocorrelación orden 1 en residuos		0.03	
% días bien clasificados (0.5)		Anual	77.38
Primavera	Verano	Otoño	Invierno
69.16	84.44	73.68	82.01
Día $t - 1$		Seco Húmedo	
Día $t$	Seco	96.68	83.72
	Húmedo	13.27	40.91
%NAS		Anual	20.83
Primavera	Verano	Otoño	Invierno
19.54	6.67	23.08	30.61
% días bien clasificados ( $\leq$ frec. día)		Anual	69.79
Primavera	Verano	Otoño	Invierno
69.16	65	64.47	77.25
Día $t - 1$		Seco Húmedo	
Día $t$	Seco	77.96	34.88
	Húmedo	58.16	80.3
%NAS		Anual	35.14
Primavera	Verano	Otoño	Invierno
41.67	24.1	32.5	38.57
Índice relativo de Brier		Anual	15.25
Primavera	Verano	Otoño	Invierno
12.71	7.19	6.85	21.93
Días de precipitación observados y predichos por meses			
Coef. correlación	0.7233	Coef. eficiencia	0.5106
Índice de acuerdo	0.8341	% medio error	2.304

Tabla B.3: Medidas de bondad de ajuste del modelo de previsión de ocurrencia para todo el año, periodo de validación 1998-2000.

Término	Coefficiente	Error std.	Estad. $t$
$\beta_0$	72.990	11.190	6.522
$S1$	-0.4854	0.1645	-2.952
$C1$	0.6223	0.4136	1.505
$P18_{t-1}$	-0.007565	0.001142	-6.626
$z.\Delta P.18.13_{t-1}$	-0.03786	0.006266	-6.042
$z.H18_{t-1}$	0.0147	0.006679	2.201
$T850.12_{t-1}$	-0.005988	0.002427	-2.467
$z.R700.12_{t-1}$	-0.00278	9.166e-4	-3.032
$dV SUP.12.NW_{t-1} : z.\Delta P.18.13_{t-1}^2$	9.540e-4	2.426e-4	3.932
$dV SUP.12.SW_{t-1} : dV500.12.sen_{t-1}$	1.153	0.5877	1.961
$dV SUP.12.SW_{t-1} : dV500.12.cos_{t-1}$	-3.044	1.189	-2.560
$dV SUP.12.este_{t-1} : T85/50.12_{t-1}$	0.002542	8.111e-4	3.134

Tabla B.4: Modelo de previsión de ocurrencia a las 18h del día previo, para los meses fríos.

		Deviance	Gr. lib.
Modelo nulo		1118.3	989
Modelo ajustado		895.56	977
AIC:	919.56	BIC:	978.32
Estad. HL	10.51	p-valor	0.23
% variabilidad explicada por modelo		22.25	
Autocorrelación orden 1 en residuos		0	
% días bien clasificados (0.5)		Global	78.67
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	97.33	76.98
	Húmedo	19.42	54.05
%NAS		Global	29.19
% días bien clasificados ( $\leq$ frec. día)		Global	73.21
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	80.83	39.57
	Húmedo	60.43	90.09
%NAS		Global	40.98
Índice relativo de Brier		Global	22.33
Días de precipitación observados y predichos por meses			
Coef. correlación	0.9702	Coef. eficiencia	0.9409
Índice de acuerdo	0.9843	% medio error	0.8219

Tabla B.5: Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses fríos (1990-1997).

AIC:	275.23	BIC:	319.51
Estad. HL	11.23	p-valor	0.19
% variabilidad explicada por modelo		18.61	
Autocorrelación orden 1 en residuos		0.09	
% días bien clasificados (0.5)		Global	81.42
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	98.02	90.62
	Húmedo	10.53	41.67
%NAS		Global	20.29
% días bien clasificados ( $\leq$ frec. día)		Global	75.34
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	82.18	40.62
	Húmedo	63.16	83.33
%NAS		Global	37.61
Índice relativo de Brier		Global	18.89
Días de precipitación observados y predichos por meses			
Coef. correlación	0.3213	Coef. eficiencia	-0.2777
Índice de acuerdo	0.6173	% medio error	5.889

Tabla B.6: Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses fríos, periodo de validación 1998-2000.

Término	Coeficiente	Error std.	Estad. $t$
$\beta_0$	-8325.000	2592.000	-3.212
$P18_{t-1}$	1.710	0.5285	3.235
$P18^2_{t-1}$	-8.778e-5	2.694e-5	-3.258
$z.\Delta P.18.13_{t-1}$	-0.04304	0.008194	-5.253
$T18_{t-1}$	-0.008332	0.002788	-2.988
$H18_{t-1}$	0.01677	0.007274	2.306
$R700.12_{t-1}$	-0.002757	0.001207	-2.284
$dV SUP.12.este_{t-1} : z.H07_{t-1}$	0.04966	0.01745	2.845
$dV SUP.12.este_{t-1} : \Delta P.7.0_{t-1}$	0.03552	0.01182	3.005
$dV SUP.12.este_{t-1} : dV500.12.sen_{t-1}$	-0.5057	0.2725	-1.856
$dV SUP.12.este_{t-1} : dV500.12.cos_{t-1}$	-0.656	0.3091	-2.123
$dV SUP.12.NW_{t-1} : dV500.12.sen_{t-1}$	-0.5401	0.2226	-2.426
$dV SUP.12.NW_{t-1} : dV500.12.cos_{t-1}$	-0.1722	0.2196	-0.7841
$dV SUP.12.calma_{t-1} : dV500.12.sen_{t-1}$	-1.569	0.7092	-2.213
$dV SUP.12.calma_{t-1} : dV500.12.cos_{t-1}$	-0.7661	0.9113	-0.8406
$dV SUP.12.SW_{t-1} : T18_{t-1}$	0.005379	0.00253	2.126

Tabla B.7: Modelo de previsión de ocurrencia a las 18h del día previo, para los meses templados.

		Deviance	Gr. lib.
Modelo nulo		900.31	801
Modelo ajustado		683.86	785
AIC:	715.86	BIC:	790.83
Estad. HL	12.74	p-valor	0.12
% variabilidad explicada por modelo			25.24
Autocorrelación orden 1 en residuos			0.04
% días bien clasificados (0.5)		Global	79.28
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	95.53	77.98
	Húmedo	24.04	57.29
%NAS		Global	32.52
% días bien clasificados ( $\leq$ frec. día)		Global	73.16
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	80.89	37.61
	Húmedo	65.38	82.29
%NAS		Global	40.61
Índice relativo de Brier		Global	25.33
Días de precipitación observados y predichos por meses			
Coef. correlación	0.8559	Coef. eficiencia	0.7316
Índice de acuerdo	0.9185	% medio error	0.7065

Tabla B.8: Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses templados (1990-1997).

AIC:	282.97	BIC:	337.49
Estad. HL	10.06	p-valor	0.26
% variabilidad explicada por modelo		16.48	
Autocorrelación orden 1 en residuos		0.11	
% días bien clasificados (0.5)		Global	72.2
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	91.82	80.56
	Húmedo	25	56.76
%NAS		Global	33.33
% días bien clasificados ( $\leq$ frec. día)		Global	67.71
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	68.18	55.56
	Húmedo	60	86.49
%NAS		Global	43.75
Índice relativo de Brier		Global	16.85
Días de precipitación observados y predichos por meses			
Coef. correlación	0.8361	Coef. eficiencia	0.5768
Índice de acuerdo	0.900	% medio error	5.311

Tabla B.9: Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses templados, periodo de validación 1998-2000.

Término	Coefficiente	Error std.	Estad. $t$
$\beta_0$	109.800	36.870	2.978
$P18_{t-1}$	-0.01125	0.003749	-3.001
$vVSUP.12_{t-1}$	-0.1516	0.03651	-4.152
$z.R700.12_{t-1}$	-0.004696	0.001881	-2.497
$dVSUP.12.este_{t-1} : z.T18_{t-1}$	-0.01099	0.00508	-2.162
$dVSUP.12.este_{t-1} : dV500.12.seno_{t-1}$	-0.9608	0.4473	-2.148
$dVSUP.12.este_{t-1} : dV500.12.coseno_{t-1}$	-1.240	0.4637	-2.673
$dVSUP.12.este_{t-1} : vV500.12_{t-1}$	-0.03506	0.01678	-2.090
$dVSUP.12.este_{t-1} : torm00.520_{t-1}$	2.148	0.6436	3.338

Tabla B.10: Modelo de previsión de ocurrencia a las 18h del día previo, para los meses cálidos.

		Deviance	Gr. lib.
Modelo nulo		476.16	529
Modelo ajustado		394.16	520
AIC:	412.16	BIC:	450.59
Estad. HL	6.04	p-valor	0.64
% variabilidad explicada por modelo		15.75	
Autocorrelación orden 1 en residuos		0.06	
% días bien clasificados (0.5)		Global	84.5
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	98.95	93.22
	Húmedo	7.02	32.26
%NAS		Global	14.58
% días bien clasificados ( $\leq$ frec. día)		Global	67.3
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	69.37	42.37
	Húmedo	64.91	93.55
%NAS		Global	27.62
Índice relativo de Brier		Global	15.91
Días de precipitación observados y predichos por meses			
Coef. correlación	0.8337	Coef. eficiencia	0.5804
Índice de acuerdo	0.8996	% medio error	2.014

Tabla B.11: Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses cálidos (1990-1997).

AIC:	153.95	BIC:	181.62
Estad. HL	21.18	p-valor	0.01
% variabilidad explicada por modelo		4.67	
Autocorrelación orden 1 en residuos		-0.09	
% días bien clasificados (0.5)		Global	83.12
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	99.14	88.24
	Húmedo	9.09	20
%NAS		Global	10
% días bien clasificados ( $\leq$ frec. día)		Global	66.88
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	69.83	41.18
	Húmedo	63.64	100
%NAS		Global	26.39
Índice relativo de Brier		Global	5.26
Días de precipitación observados y predichos por meses			
Coef. correlación	0.7744	Coef. eficiencia	0.5687
Índice de acuerdo	0.8357	% medio error	0.1688

Tabla B.12: Medidas de bondad de ajuste del modelo de previsión de ocurrencia, para los meses cálidos, periodo de validación 1998-2000.

Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-3639.000	785.400	-4.633
$P18_{t-1}$	0.7397	0.1597	4.631
$P18_{t-1}^2$	-3.795e-5	8.132e-6	-4.667
$z.H18_{t-1}$	8.54e-3	3.567e-3	2.394
$P00_{t-1}$	3.981e-3	1.508e-3	2.641
Parámetro de dispersión de la distribución Gamma: 1.978			

Tabla B.13: Modelo de previsión de cantidad a las 18h del día previo.

		Deviance	Gr. lib.	
Modelo nulo		1118.13	615	
Modelo ajustado		1048.24	610	
AIC:	5287.78	BIC:	5309.89	
% variabilidad explicada por modelo		3.56		
Primavera	Verano	Otoño	Invierno	
3.58	0	0.79	12.15	
Autocorrelación orden 1 en residuos		0.03		
Cantidad media de precipitación observada y predicha por meses				
Coef. correlación	0.4392	Coef. eficiencia	0.1869	
Índice de acuerdo	0.4833	% medio error	8.380	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
0.000	18.050	58.050	15.120	8.780
% días clasificados en los intervalos, si el día anterior seco				
0.000	19.020	58.790	14.700	7.493
% días clasificados en los intervalos, si el día anterior llovió				
0.000	16.790	57.090	15.670	10.450
% días	Primavera	Verano	Otoño	Invierno
$(q_{0.10}, q_{0.90})$	89.710	92.920	90.000	92.610

Tabla B.14: Medidas de bondad de ajuste del modelo de previsión para la cantidad en un día con lluvia (1990-1997).

AIC:		1722.28		BIC:		1739.13		
% variabilidad explicada por modelo						0.92		
Primavera		Verano		Otoño		Invierno		
0		5.54		0.5		0		
Autocorrelación orden 1 en residuos						-0.12		
Cantidad media de precipitación observada y predicha por meses								
Coef. correlación		0.8554		Coef. eficiencia		-0.4776		
Índice de acuerdo		0.6861		% medio error		25.470		
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada								
$< q_{0.10}$		$[q_{0.10}, q_{0.25})$		$[q_{0.25}, q_{0.75}]$		$(q_{0.75}, q_{0.90}]$		$> q_{0.90}$
0.000		22.790		58.140		11.630		7.442
% días clasificados en los intervalos, si el día anterior seco								
0.000		20.310		60.160		14.060		5.469
% días clasificados en los intervalos, si el día anterior llovió								
0.000		26.440		55.170		8.046		10.340
% días ( $q_{0.10}, q_{0.90}$ )		Primavera		Verano		Otoño		Invierno
		89.890		92.310		95.240		95.560

Tabla B.15: Medidas de bondad de ajuste del modelo de previsión para la cantidad en un día con lluvia, periodo de validación 1998-2000.

## B.2 Tablas para la comparación con las previsiones HIRLAM

	Observado	TP	LSP	CP
Media	7.375	17.785	7.475	10.291
Desv. tip.	27.513	49.887	29.233	35.088
$P(Q > 0)$	0.237	0.643	0.595	0.32
$P(Q > 10)$	0.128	0.232	0.105	0.15
$P(Q > 50)$	0.046	0.091	0.038	0.055
Media ( $Q_t > 0$ )	31.166	27.661	11.625	16.005
Desv. tip. ( $Q_t > 0$ )	49.635	59.991	35.796	42.709
$\rho(Q_t, Q_{t-1})$	0.072	0.249	0.088	0.234
$P(Q_t > 0   Q_{t-1} > 0)$	0.425	0.738	0.7	0.585
Longitud de rachas secas				
Media	5.801	2.167	2.301	5.261
Desv. tip.	6.542	1.527	1.681	7.243
Longitud de rachas húmedas				
Media	1.697	3.853	3.378	2.417
Desv. tip.	1.283	3.193	2.8	2.276
Cor(obs,HIRLAM)		0.355	0.251	0.295

Tabla B.16: Características de la lluvia diaria observada y prevista por HIRLAM.

	Obs.	TP	LSP	CP
Enero				
Media	4.554	7.12	5.848	1.228
Desv. tip.	16.086	17.139	15.556	5.131
$P(Q > 0)$	0.207	0.565	0.543	0.141
$P(Q > 10)$	0.076	0.163	0.13	0.022
$P(Q > 50)$	0.043	0.043	0.033	0
Media ( $Q_t > 0$ )	22.053	12.596	10.346	2.173
Desv. tip. ( $Q_t > 0$ )	30.014	21.302	19.605	6.7
$\rho(Q_t, Q_{t-1})$	0.166	0.06	0.002	0.483
$P(Q_t > 0   Q_{t-1} > 0)$	0.45	0.642	0.627	0.583
Longitud de rachas secas				
Media	12.2	2.316	2.421	4.2
Desv. tip.	18.6	1.734	1.677	2.95
Longitud de rachas húmedas				
Media	1.417	3.059	3	2.667
Desv. tip.	0.515	2.633	2.598	1.506
Cor(obs,HIRLAM)		0.515	0.397	0.516
Febrero				
Media	3.205	3.843	2.446	1.41
Desv. tip.	18.887	10.814	8.233	5.14
$P(Q > 0)$	0.133	0.518	0.518	0.229
$P(Q > 10)$	0.048	0.06	0.024	0.048
$P(Q > 50)$	0.012	0.012	0.012	0
Media ( $Q_t > 0$ )	24.182	7.419	4.721	2.721
Desv. tip. ( $Q_t > 0$ )	48.651	14.183	11.016	6.922
$\rho(Q_t, Q_{t-1})$	0.007	0.372	0.004	0.319
$P(Q_t > 0   Q_{t-1} > 0)$	0.5	0.651	0.651	0.316
Longitud de rachas secas				
Media	7.333	2.467	2.467	4.385
Desv. tip.	5.465	2.356	2.356	6.09
Longitud de rachas húmedas				
Media	2	2.6	2.6	1.462
Desv. tip.	0.894	2.823	2.823	0.66
Cor(obs,HIRLAM)		0.211	0.208	0.117
Marzo				
Media	7.032	16.398	7.806	8.538
Desv. tip.	19.182	41.14	24.458	27.389
$P(Q > 0)$	0.237	0.591	0.538	0.43
$P(Q > 10)$	0.183	0.247	0.118	0.151
$P(Q > 50)$	0.054	0.086	0.054	0.032
Media ( $Q_t > 0$ )	29.727	27.727	13.2	14.436
Desv. tip. ( $Q_t > 0$ )	30.086	50.632	30.767	34.515
$\rho(Q_t, Q_{t-1})$	0.614	0.557	0.286	0.116
$P(Q_t > 0   Q_{t-1} > 0)$	0.476	0.755	0.708	0.73
Longitud de rachas secas				
Media	5.667	2.846	3	5
Desv. tip.	4.717	2.672	2.602	2.906
Longitud de rachas húmedas				
Media	1.786	4.267	3.625	3.538
Desv. tip.	1.251	4.431	2.918	4.594
Cor(obs,HIRLAM)		0.835	0.677	0.649
Abril				
Media	13.864	22.841	6.864	15.943
Desv. tip.	48.183	39.563	19.767	31.218
$P(Q > 0)$	0.398	0.807	0.705	0.636
$P(Q > 10)$	0.182	0.386	0.136	0.307
$P(Q > 50)$	0.068	0.148	0.023	0.102
Media ( $Q_t > 0$ )	34.857	28.31	8.507	19.761
Desv. tip. ( $Q_t > 0$ )	72.022	42.289	21.712	33.686
$\rho(Q_t, Q_{t-1})$	0.047	0.257	-0.031	0.086
$P(Q_t > 0   Q_{t-1} > 0)$	0.514	0.841	0.75	0.75
Longitud de rachas secas				
Media	2.714	1.545	1.733	2.571
Desv. tip.	2.199	0.688	1.223	2.102
Longitud de rachas húmedas				
Media	2.2	6.545	4.267	4
Desv. tip.	1.322	5.106	3.882	3.742
Cor(obs,HIRLAM)		0.46	0.76	0.101
Mayo				
Media	12.207	34.967	6.435	28.489
Desv. tip.	38.622	68.398	16.536	61.386
$P(Q > 0)$	0.315	0.728	0.652	0.533
$P(Q > 10)$	0.174	0.413	0.13	0.359
$P(Q > 50)$	0.054	0.207	0.043	0.185
Media ( $Q_t > 0$ )	38.724	48.015	8.836	39.119
Desv. tip. ( $Q_t > 0$ )	61.517	76.252	18.854	69.09
$\rho(Q_t, Q_{t-1})$	-0.007	0.357	0.468	0.254
$P(Q_t > 0   Q_{t-1} > 0)$	0.517	0.791	0.783	0.647
Longitud de rachas secas				
Media	4.583	1.786	2.462	2.5
Desv. tip.	2.712	0.802	1.391	1.689
Longitud de rachas húmedas				
Media	2	4.615	4.167	3.133
Desv. tip.	1.713	3.664	3.46	2.532
Cor(obs,HIRLAM)		0.13	0.066	0.126
Junio				
Media	9.828	20.259	7.784	12.474
Desv. tip.	40.961	54.464	31.201	39.069
$P(Q > 0)$	0.181	0.707	0.612	0.379
$P(Q > 10)$	0.121	0.276	0.078	0.198
$P(Q > 50)$	0.052	0.078	0.043	0.052
Media ( $Q_t > 0$ )	54.286	28.659	11.012	17.646
Desv. tip. ( $Q_t > 0$ )	84.34	62.99	36.69	45.549
$\rho(Q_t, Q_{t-1})$	-0.004	0.073	0.03	0.05
$P(Q_t > 0   Q_{t-1} > 0)$	0.391	0.712	0.652	0.548
Longitud de rachas secas				
Media	7.571	1.696	2.125	4.211
Desv. tip.	7.562	1.02	1.597	4.341
Longitud de rachas húmedas				
Media	1.357	3.727	3.043	1.944
Desv. tip.	0.497	2.729	2.531	1.211
Cor(obs,HIRLAM)		0.682	0.26	0.742

Tabla B.17: Características por meses de la lluvia diaria observada y prevista HIRLAM.

	Obs.	TP	LSP	CP
Julio				
Media	7.041	15.561	5.081	10.488
Desv. tip.	25.436	46.869	20.793	33.699
$P(Q > 0)$	0.187	0.593	0.553	0.317
$P(Q > 10)$	0.13	0.187	0.057	0.138
$P(Q > 50)$	0.049	0.073	0.024	0.057
Media ( $Q_t > 0$ )	37.652	26.219	8.562	17.671
Desv. tip. ( $Q_t > 0$ )	48.815	58.641	26.503	42.374
$\rho(Q_t, Q_{t-1})$	0.011	0.107	0.222	0.098
$P(Q_t > 0   Q_{t-1} > 0)$	0.286	0.722	0.672	0.487
Longitud de rachas secas				
Media	6.133	2.4	2.364	4.25
Desv. tip.	3.378	1.465	1.465	3.919
Longitud de rachas húmedas				
Media	1.375	3.619	3.261	2.25
Desv. tip.	0.619	3.232	3.194	1.743
Cor(obs,HIRLAM)		0.243	0.273	0.169
Agosto				
Media	5.417	24.475	9.717	14.725
Desv. tip.	23.61	64.258	54.157	34.479
$P(Q > 0)$	0.167	0.658	0.575	0.4
$P(Q > 10)$	0.075	0.275	0.083	0.225
$P(Q > 50)$	0.033	0.142	0.025	0.108
Media ( $Q_t > 0$ )	32.5	37.177	14.759	22.367
Desv. tip. ( $Q_t > 0$ )	50.645	76.297	66.327	40.504
$\rho(Q_t, Q_{t-1})$	-0.035	0.062	0.005	0.1
$P(Q_t > 0   Q_{t-1} > 0)$	0.15	0.763	0.682	0.583
Longitud de rachas secas				
Media	6.824	2.222	2.476	4.1
Desv. tip.	6.598	1.517	2.228	3.905
Longitud de rachas húmedas				
Media	1.467	4	3.136	2.111
Desv. tip.	0.64	3.48	3.121	1.491
Cor(obs,HIRLAM)		0.251	-0.004	0.474
Septiembre				
Media	5.102	29.381	12.89	16.432
Desv. tip.	15.077	82.014	46.056	55.397
$P(Q > 0)$	0.203	0.661	0.602	0.331
$P(Q > 10)$	0.119	0.263	0.119	0.178
$P(Q > 50)$	0.051	0.11	0.059	0.068
Media ( $Q_t > 0$ )	25.083	44.449	19.5	24.859
Desv. tip. ( $Q_t > 0$ )	25.165	97.684	55.61	66.714
$\rho(Q_t, Q_{t-1})$	0.389	0.233	0.026	0.289
$P(Q_t > 0   Q_{t-1} > 0)$	0.385	0.731	0.694	0.605
Longitud de rachas secas				
Media	5.538	2	2	5.867
Desv. tip.	3.045	1.265	1.304	4.658
Longitud de rachas húmedas				
Media	1.722	3.526	3.05	2.643
Desv. tip.	2.109	2.342	2.064	1.55
Cor(obs,HIRLAM)		0.466	0.396	0.36
Octubre				
Media	6.44	14.088	7.363	6.714
Desv. tip.	17.123	39.427	17.553	29.62
$P(Q > 0)$	0.275	0.637	0.626	0.143
$P(Q > 10)$	0.165	0.187	0.143	0.077
$P(Q > 50)$	0.033	0.077	0.055	0.033
Media ( $Q_t > 0$ )	23.44	22.103	11.552	10.534
Desv. tip. ( $Q_t > 0$ )	26.16	47.688	20.91	36.665
$\rho(Q_t, Q_{t-1})$	-0.038	0.398	0.126	0.357
$P(Q_t > 0   Q_{t-1} > 0)$	0.423	0.745	0.722	0.462
Longitud de rachas secas				
Media	4	2.071	2	12.571
Desv. tip.	2.903	1.072	1.069	19.234
Longitud de rachas húmedas				
Media	1.562	4.533	4.188	1.857
Desv. tip.	0.814	3.204	2.88	1.464
Cor(obs,HIRLAM)		0.231	0.12	0.234
Noviembre				
Media	7.989	8.534	7.466	1.08
Desv. tip.	22.657	22.529	21.095	4.47
$P(Q > 0)$	0.25	0.659	0.659	0.125
$P(Q > 10)$	0.114	0.125	0.102	0.023
$P(Q > 50)$	0.08	0.057	0.045	0
Media ( $Q_t > 0$ )	31.955	12.948	11.328	1.638
Desv. tip. ( $Q_t > 0$ )	36.391	26.768	25.193	5.438
$\rho(Q_t, Q_{t-1})$	0.24	0.372	0.388	0.001
$P(Q_t > 0   Q_{t-1} > 0)$	0.391	0.789	0.789	0.3
Longitud de rachas secas				
Media	4.75	2.583	2.583	11.143
Desv. tip.	3.571	1.881	1.881	13.397
Longitud de rachas húmedas				
Media	1.737	4.167	4.167	1.375
Desv. tip.	1.881	1.749	1.749	0.744
Cor(obs,HIRLAM)		0.443	0.463	0.059
Diciembre				
Media	6.424	9.174	7.989	1.207
Desv. tip.	19.425	24.408	22.004	6.11
$P(Q > 0)$	0.348	0.576	0.576	0.13
$P(Q > 10)$	0.163	0.174	0.152	0.022
$P(Q > 50)$	0.022	0.043	0.043	0
Media ( $Q_t > 0$ )	18.469	15.925	13.868	2.094
Desv. tip. ( $Q_t > 0$ )	29.632	30.546	27.644	7.964
$\rho(Q_t, Q_{t-1})$	0.167	0.392	0.376	-0.02
$P(Q_t > 0   Q_{t-1} > 0)$	0.516	0.654	0.654	0.308
Longitud de rachas secas				
Media	4.5	2.222	2.222	12.889
Desv. tip.	3.299	1.003	1.003	13.842
Longitud de rachas húmedas				
Media	1.684	2.944	2.889	1.429
Desv. tip.	1.108	2.014	2.055	0.787
Cor(obs,HIRLAM)		0.619	0.629	0.209

Tabla B.18: Características por meses de la lluvia diaria observada y prevista HIRLAM. Continuación.

	Obs	Estad.	TP	LSP
$P(Y_t = 1)$	0.25	0.24	0.65	0.596
$P(Y_t = 1   Y_{t-1} = 1)$	0.46	0.408	0.832	0.787
$P(Y_t = 1   \hat{Y}_{t-1} = 1)$		0.443	0.741	0.698
$P(Y_t = 1   Y_{t-1} = 0)$	0.181	0.185	0.591	0.534
$P(Y_t = 1   \hat{Y}_{t-1} = 0)$		0.213	0.484	0.445
Cor(obs,previsión)		0.29	0.365	0.377
%aciertos		68	57.6	61.2
%aciertos Primavera		68.75	60.268	64.732
%aciertos Verano		64.885	52.29	57.252
%aciertos Otoño		61.789	53.659	57.724
%aciertos Invierno		74.882	63.507	64.455
%aciertos si $Y_{t-1} = 0$		72.2	62.1	66
%aciertos si $Y_{t-1} = 1$		54.4	54.1	57.8
%aciertos $Y_t = 0 = Y_{t-1}$		74.653	49.012	54.743
%aciertos $Y_t = 1, Y_{t-1} = 0$		62.295	95.536	90.179
%aciertos $Y_t = 0, Y_{t-1} = 1$		32.143	26.606	33.945
%aciertos $Y_t = 1 = Y_{t-1}$		85.185	94.624	93.548
$\%Y_t : Y_{t-1}$		63.569	66.444	68.104

Tabla B.19: Comparación entre la ocurrencia de lluvia diaria observada, prevista por el modelo estadístico anual y prevista por HIRLAM (umbral 1dl).

	Obs	E. an.	TP	LSP
$P(Y_t = 1)$	0.248	0.248	0.575	0.558
$P(Y_t = 1   Y_{t-1} = 1)$	0.519	0.46	0.802	0.79
$P(Y_t = 1   \hat{Y}_{t-1} = 1)$		0.461	0.697	0.683
$P(Y_t = 1   Y_{t-1} = 0)$	0.163	0.181	0.504	0.484
$P(Y_t = 1   \hat{Y}_{t-1} = 0)$		0.206	0.407	0.397
Cor(obs,previsión)		0.339	0.396	0.401
%aciertos		74.6	63.1	64.3
%aciertos si $Y_{t-1} = 0$		79	66.4	67.9
%aciertos si $Y_{t-1} = 1$		58.3	60	61
%aciertos $Y_t = 0 = Y_{t-1}$		81.448	57.87	59.722
%aciertos $Y_t = 1, Y_{t-1} = 0$		67.391	92.857	90.476
%aciertos $Y_t = 0, Y_{t-1} = 1$		35.714	30.769	33.333
%aciertos $Y_t = 1 = Y_{t-1}$		90	90.476	90.476
$\%Y_t : Y_{t-1}$		68.638	67.993	68.502

Tabla B.20: Comparación entre la ocurrencia de lluvia diaria observada en los meses fríos, prevista por el modelo estadístico anual y prevista por HIRLAM (umbral 1dl).

	Obs.	E. templ.	TP
$P(Y_t = 1)$	0.297	0.301	0.727
$P(Y_t = 1   Y_{t-1} = 1)$	0.488	0.44	0.85
$P(Y_t = 1   \hat{Y}_{t-1} = 1)$		0.453	0.762
$P(Y_t = 1   Y_{t-1} = 0)$	0.207	0.235	0.669
$P(Y_t = 1   \hat{Y}_{t-1} = 0)$		0.263	0.609
Cor(obs,previsión)		0.357	0.359
%aciertos		66.7	55.4
%aciertos si $Y_{t-1} = 0$		65.5	54.7
%aciertos si $Y_{t-1} = 1$		69.2	55.2
%aciertos $Y_t = 0 = Y_{t-1}$		66.923	41.045
%aciertos $Y_t = 1, Y_{t-1} = 0$		60.976	97.143
%aciertos $Y_t = 0, Y_{t-1} = 1$		52.5	26.829
%aciertos $Y_t = 1 = Y_{t-1}$		86.842	97.436
$\%Y_t : Y_{t-1}$		66.81	65.613

Tabla B.21: Comparación entre la ocurrencia de lluvia diaria observada en los meses templados, prevista por el modelo estadístico específico y prevista por HIRLAM (umbral 1dl).

	Obs.	E. an.	TP	E. cal.
$P(Y_t = 1)$	0.202	0.189	0.678	0.198
$P(Y_t = 1   Y_{t-1} = 1)$	0.293	0.298	0.854	0.333
$P(Y_t = 1   \hat{Y}_{t-1} = 1)$		0.182	0.774	0.252
$P(Y_t = 1   Y_{t-1} = 0)$	0.182	0.165	0.641	0.159
$P(Y_t = 1   \hat{Y}_{t-1} = 0)$		0.189	0.519	0.195
Cor(obs,previsión)		0.291	0.323	0.462
%aciertos		63.9	51.5	62.5
%aciertos si $Y_{t-1} = 0$		67.4	60.5	63.3
%aciertos si $Y_{t-1} = 1$		48.8	44.5	60
%aciertos $Y_t = 0 = Y_{t-1}$		65.806	43.312	63.043
%aciertos $Y_t = 1, Y_{t-1} = 0$		74.286	97.143	64.286
%aciertos $Y_t = 0, Y_{t-1} = 1$		26.667	20.69	33.333
%aciertos $Y_t = 1 = Y_{t-1}$		100	100	100
$\%Y_t : Y_{t-1}$		66.69	65.286	65.166

Tabla B.22: Comparación entre la ocurrencia de lluvia diaria observada en los meses cálidos, prevista por los modelos estadísticos y prevista por HIRLAM (umbral 1dl).

	Obs.	E. an.	TP
$P(Y_t = 1)$	0.248	0.248	0.245
$P(Y_t = 1 Y_{t-1} = 1)$	0.519	0.46	0.444
$P(Y_t = 1 \hat{Y}_{t-1} = 1)$		0.461	0.333
$P(Y_t = 1 Y_{t-1} = 0)$	0.163	0.181	0.182
$P(Y_t = 1 \hat{Y}_{t-1} = 0)$		0.206	0.121
Cor(obs,previsión)		0.339	0.531
%aciertos		74.6	82.6
%aciertos si $Y_{t-1} = 0$		79	82.1
%aciertos si $Y_{t-1} = 1$		58.3	83.1
%aciertos $Y_t = 0 = Y_{t-1}$		81.448	89.815
%aciertos $Y_t = 1, Y_{t-1} = 0$		67.391	59.524
%aciertos $Y_t = 0, Y_{t-1} = 1$		35.714	82.051
%aciertos $Y_t = 1 = Y_{t-1}$		90	69.048
$\%Y_t : Y_{t-1}$		68.638	75.109

Tabla B.23: Comparación entre la ocurrencia de lluvia diaria observada, prevista por el modelo estadístico anual y prevista por HIRLAM (umbral 6dl), para los meses fríos.

	Obs.	E. templ.	TP
$P(Y_t = 1)$	0.297	0.301	0.325
$P(Y_t = 1 Y_{t-1} = 1)$	0.488	0.44	0.475
$P(Y_t = 1 \hat{Y}_{t-1} = 1)$		0.453	0.37
$P(Y_t = 1 Y_{t-1} = 0)$	0.207	0.235	0.254
$P(Y_t = 1 \hat{Y}_{t-1} = 0)$		0.263	0.172
Cor(obs,previsión)		0.357	0.468
%aciertos		66.7	77.1
%aciertos si $Y_{t-1} = 0$		65.5	82.8
%aciertos si $Y_{t-1} = 1$		69.2	75.7
%aciertos $Y_t = 0 = Y_{t-1}$		66.923	85.075
%aciertos $Y_t = 1, Y_{t-1} = 0$		60.976	65.714
%aciertos $Y_t = 0, Y_{t-1} = 1$		52.5	70.732
%aciertos $Y_t = 1 = Y_{t-1}$		86.842	66.667
$\%Y_t : Y_{t-1}$		66.81	72.047

Tabla B.24: Comparación entre la ocurrencia de lluvia diaria observada, prevista por el modelo estadístico específico y prevista por HIRLAM (umbral 13dl), para los meses templados.

	Obs.	E. an.	TP	E. cal.
$P(Y_t = 1)$	0.202	0.189	0.189	0.198
$P(Y_t = 1 Y_{t-1} = 1)$	0.293	0.298	0.366	0.333
$P(Y_t = 1 \hat{Y}_{t-1} = 1)$		0.182	0.247	0.273
$P(Y_t = 1 Y_{t-1} = 0)$	0.182	0.165	0.151	0.159
$P(Y_t = 1 \hat{Y}_{t-1} = 0)$		0.189	0.074	0.195
Cor(obs,previsión)		0.291	0.468	0.462
%aciertos		63.9	83.3	62.5
%aciertos si $Y_{t-1} = 0$		67.4	90.1	63.3
%aciertos si $Y_{t-1} = 1$		48.8	79.5	60
%aciertos $Y_t = 0 = Y_{t-1}$		65.806	92.357	63.043
%aciertos $Y_t = 1, Y_{t-1} = 0$		74.286	48.571	64.286
%aciertos $Y_t = 0, Y_{t-1} = 1$		26.667	79.31	33.333
%aciertos $Y_t = 1 = Y_{t-1}$		100	75	100
$\%Y_t : Y_{t-1}$		66.69	73.81	65.166

Tabla B.25: Comparación entre la ocurrencia de lluvia diaria observada, prevista por los modelos estadísticos y prevista por HIRLAM (umbral 19dl), para los meses cálidos.



# Apéndice C

## Tablas del downscaling

### C.1 Comparación de los datos observados y simulados por CGCM1

Variable	$\bar{x}$		$\hat{s}$		$Q_1$		$Q_3$	
	Obs.	Sim.	Obs.	Sim.	Obs.	Sim.	Obs.	Sim.
Lluvia ( $10^{-1}$ mm)	7.998	13.69	29.72	24.8	0.0	0.236	0.0	16.19
<i>TMAX</i> ( $10^{-1}$ °C)	211.8	204.4	84.67	80.6	144.0	139.6	282.0	260.0
<i>TMIN</i> ( $10^{-1}$ °C)	100.1	103.0	64.34	60.46	50.0	58.76	154.0	142.7
<i>TDIF</i> ( $10^{-1}$ °C)	111.7	101.4	39.42	44.68	84.0	66.1	141.0	132.9
<i>PSUP</i> ( $10^{-1}$ hPa)	9872.0	9912.0	67.12	70.07	9830.0	9866.0	9915.0	9958.0
<i>QSUP</i> (kg/kg)	0.0070	0.0096	0.0026	0.0024	0.0051	0.0079	0.0087	0.0111
<i>USUP</i> (m/seg)	2.24	0.9623	3.562	3.046	-0.492	-1.23	4.893	3.05
<i>VSUP</i> (m/seg)	-1.319	0.5239	2.271	2.708	-2.651	-1.357	0.2605	2.378
<i>T850.00</i> ( $10^{-1}$ °C)	92.28	92.69	67.27	62.53	42.0	47.34	142.0	129.8
<i>A850.00</i> (m)	1530.0	1511.0	60.78	56.34	1496.0	1481.0	1573.0	1549.0
<i>Q850.00</i> (kg/kg)	0.0066	0.0052	0.0027	0.0022	0.0045	0.0037	0.0084	0.0066
<i>U850.00</i> (m/seg)	3.882	4.974	5.876	6.037	-0.249	0.665	7.704	8.643
<i>V850.00</i> (m/seg)	-1.886	0.4906	6.558	5.984	-5.353	-3.353	2.57	4.484
<i>T500.00</i> ( $10^{-1}$ °C)	-169.3	-156.0	54.95	48.82	-207.0	-193.4	-127.0	-114.4
<i>A500.00</i> (m)	5723.0	5692.0	128.7	108.3	5640.0	5621.0	5820.0	5778.0
<i>Q500.00</i> (kg/kg)	0.0013	0.0013	6.8e-4	7.1e-4	7.4e-4	7.5e-4	0.0017	0.0017
<i>U500.00</i> (m/seg)	8.188	11.49	10.07	7.768	1.741	6.339	14.5	16.36
<i>V500.00</i> (m/seg)	-1.604	-0.208	10.18	8.346	-7.501	-5.028	4.83	5.255
<i>T85/50.00</i> ( $10^{-1}$ °C)	261.7	248.7	35.95	36.86	239.0	223.7	285.0	269.2
<i>A85/50.00</i> (m)	-4192	-4181	86.91	77.57	-4259	-4243	-4132	-4122

Tabla C.1: Momentos y cuartiles de las variables observadas y generadas para el conjunto del periodo 1990-2000.

Invierno								
Variable	$\bar{x}$		$\hat{s}$		$Q_1$		$Q_3$	
	Obs.	Sim.	Obs.	Sim.	Obs.	Sim.	Obs.	Sim.
Lluvia ( $10^{-1}$ mm)	7.204	22.47	24.33	29.67	0.0	4.125	0.0	30.17
<i>TMAX</i> ( $10^{-1}$ °C)	117.1	128.8	39.84	21.14	93.0	116.8	144.0	142.6
<i>TMIN</i> ( $10^{-1}$ °C)	30.08	58.38	35.99	33.78	4.0	30.96	55.5	84.96
<i>TDIF</i> ( $10^{-1}$ °C)	87.01	70.41	34.98	30.0	61.5	47.04	110.0	92.58
<i>PSUP</i> ( $10^{-1}$ hPa)	9908.0	9925.0	81.86	81.36	9859.0	9878.0	9967.0	9983.0
<i>QSUP</i> (kg/kg)	0.0048	0.0079	0.0012	0.0012	0.0040	0.0072	0.0056	0.0088
<i>USUP</i> (m/seg)	2.465	2.711	3.388	2.392	-0.087	1.087	5.03	4.319
<i>VSUP</i> (m/seg)	-1.099	1.355	2.323	2.348	-2.291	-0.158	0.3907	2.801
<i>T850.00</i> ( $10^{-1}$ °C)	35.43	40.0	40.26	26.74	8.0	23.03	64.0	59.2
<i>A850.00</i> (m)	1530.0	1497.0	70.51	67.46	1486.0	1454.0	1581.0	1546.0
<i>Q850.00</i> (kg/kg)	0.0043	0.0042	0.0013	0.0016	0.0034	0.0031	0.0052	0.0053
<i>U850.00</i> (m/seg)	4.901	9.101	6.526	6.249	0.866	4.722	8.678	13.11
<i>V850.00</i> (m/seg)	-3.025	0.9981	7.391	6.58	-6.928	-3.111	1.997	5.353
<i>T500.00</i> ( $10^{-1}$ °C)	-210.7	-201.2	41.82	29.6	-237.0	-220.8	-181.0	-179.7
<i>A500.00</i> (m)	5654.0	5606.0	113.8	89.37	5570.0	5548.0	5740.0	5671.0
<i>Q500.00</i> (kg/kg)	8.8e-4	9.4e-4	4.4e-4	4.7e-4	5.4e-4	5.9e-4	0.0012	0.0013
<i>U500.00</i> (m/seg)	7.186	14.31	12.16	8.934	-0.130	8.3	14.72	20.38
<i>V500.00</i> (m/seg)	-4.288	-0.379	11.49	9.48	-11.32	-6.283	3.817	5.996
<i>T85/50.00</i> ( $10^{-1}$ °C)	245.8	241.2	30.83	23.9	227.0	225.5	269.0	258.1
<i>A85/50.00</i> (m)	-4124	-4109	61.12	43.2	-4168	-4139	-4085	-4080

Primavera								
Variable	$\bar{x}$		$\hat{s}$		$Q_1$		$Q_3$	
	Obs.	Sim.	Obs.	Sim.	Obs.	Sim.	Obs.	Sim.
Lluvia ( $10^{-1}$ mm)	9.852	16.44	34.58	25.71	0.0	1.832	0.0	21.09
<i>TMAX</i> ( $10^{-1}$ °C)	207.1	164.8	50.49	36.33	168.0	138.9	240.0	186.0
<i>TMIN</i> ( $10^{-1}$ °C)	85.63	87.74	39.2	37.79	60.0	60.76	112.0	114.1
<i>TDIF</i> ( $10^{-1}$ °C)	121.5	77.08	38.09	27.7	93.0	55.65	150.0	96.99
<i>PSUP</i> ( $10^{-1}$ hPa)	9856.0	9914.0	68.28	71.43	9812.0	9866.0	9903.0	9961.0
<i>QSUP</i> (kg/kg)	0.0061	0.0090	0.0017	0.0018	0.0048	0.0078	0.0071	0.0101
<i>USUP</i> (m/seg)	2.42	1.216	3.847	3.167	-0.488	-1.058	5.26	3.479
<i>VSUP</i> (m/seg)	-1.507	0.1955	2.539	2.924	-3.041	-1.877	0.306	2.324
<i>T850.00</i> ( $10^{-1}$ °C)	73.65	65.64	48.69	39.48	38.0	39.19	108.0	88.02
<i>A850.00</i> (m)	1511.0	1499.0	64.32	57.84	1472.0	1463.0	1558.0	1540.0
<i>Q850.00</i> (kg/kg)	0.0056	0.0045	0.0017	0.0018	0.0044	0.0032	0.0067	0.0057
<i>U850.00</i> (m/seg)	3.596	4.358	5.62	6.187	-0.458	0.055	7.471	8.349
<i>V850.00</i> (m/seg)	-1.992	-0.400	6.692	6.681	-5.629	-4.975	2.631	4.041
<i>T500.00</i> ( $10^{-1}$ °C)	-195.3	-179.3	41.01	35.24	-217.0	-201.9	-169.0	-153.9
<i>A500.00</i> (m)	5665.0	5646.0	111.9	89.89	5590.0	5586.0	5750.0	5713.0
<i>Q500.00</i> (kg/kg)	0.0010	0.0010	4.8e-4	5.5e-4	6.4e-4	6.1e-4	0.0013	0.0014
<i>U500.00</i> (m/seg)	6.809	10.75	9.562	8.275	1.e-15	5.512	13.08	16.43
<i>V500.00</i> (m/seg)	-1.651	-1.199	10.36	9.452	-7.727	-7.685	4.589	5.527
<i>T85/50.00</i> ( $10^{-1}$ °C)	269.2	245.0	31.2	30.6	251.0	224.1	291.0	264.4
<i>A85/50.00</i> (m)	-4155	-4146	62.41	54.84	-4198	-4186	-4119	-4111

Tabla C.2: Momentos y cuartiles de las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en Invierno y Primavera.

## Verano

Variable	$\bar{x}$		$\hat{s}$		$Q_1$		$Q_3$	
	Obs.	Sim.	Obs.	Sim.	Obs.	Sim.	Obs.	Sim.
Lluvia ( $10^{-1}$ mm)	5.629	6.915	24.83	19.54	0.0	2.e-14	0.0	4.429
<i>TMAX</i> ( $10^{-1}$ °C)	309.4	297.4	45.44	59.57	280.0	250.8	344.0	340.3
<i>TMIN</i> ( $10^{-1}$ °C)	173.7	168.4	28.67	47.81	154.0	134.9	195.0	199.1
<i>TDIF</i> ( $10^{-1}$ °C)	135.7	129.0	30.53	36.97	114.0	104.3	157.0	155.1
<i>PSUP</i> ( $10^{-1}$ hPa)	9861.0	9879.0	36.23	46.24	9837.0	9846.0	9886.0	9912.0
<i>QSUP</i> (kg/kg)	0.0095	0.0119	0.0023	0.0022	0.0077	0.0105	0.0111	0.0133
<i>USUP</i> (m/seg)	2.025	-1.029	3.591	2.936	-0.834	-3.18	4.763	1.158
<i>VSUP</i> (m/seg)	-1.569	0.00923	2.012	2.952	-2.934	-2.349	0.0	2.186
<i>T850.00</i> ( $10^{-1}$ °C)	165.8	160.3	48.21	51.51	136.0	121.4	202.0	197.6
<i>A850.00</i> (m)	1555.0	1515.0	34.68	33.32	1533.0	1495.0	1580.0	1540.0
<i>Q850.00</i> (kg/kg)	0.0096	0.0068	0.0023	0.0021	0.0080	0.0055	0.0113	0.0083
<i>U850.00</i> (m/seg)	2.251	1.673	4.654	3.729	-1.205	-1.0	5.517	3.935
<i>V850.00</i> (m/seg)	-0.584	0.762	5.183	4.867	-2.977	-2.431	2.867	3.913
<i>T500.00</i> ( $10^{-1}$ °C)	-113.4	-102.0	30.6	23.31	-130.5	-116.1	-93.0	-85.0
<i>A500.00</i> (m)	5842.0	5784.0	75.42	61.01	5800.0	5749.0	5900.0	5829.0
<i>Q500.00</i> (kg/kg)	0.0018	0.0018	7.0e-4	7.8e-4	0.0013	0.0012	0.0023	0.0023
<i>U500.00</i> (m/seg)	9.742	11.21	7.755	5.297	4.532	7.589	14.75	14.83
<i>V500.00</i> (m/seg)	0.6266	1.378	7.933	5.865	-4.365	-2.511	5.142	5.254
<i>T85/50.00</i> ( $10^{-1}$ °C)	279.1	262.3	38.12	45.01	257.0	227.0	303.0	297.3
<i>A85/50.00</i> (m)	-4287	-4269	51.88	42.49	-4325	-4300	-4260	-4240

## Otoño

Variable	$\bar{x}$		$\hat{s}$		$Q_1$		$Q_3$	
	Obs.	Sim.	Obs.	Sim.	Obs.	Sim.	Obs.	Sim.
Lluvia ( $10^{-1}$ mm)	9.346	9.097	33.46	19.8	0.0	0.02407	0.25	8.699
<i>TMAX</i> ( $10^{-1}$ °C)	208.7	225.2	62.73	65.44	164.0	171.9	255.0	269.8
<i>TMIN</i> ( $10^{-1}$ °C)	107.0	96.49	48.28	56.65	74.0	52.89	143.0	138.7
<i>TDIF</i> ( $10^{-1}$ °C)	101.7	128.7	35.28	43.61	76.75	100.6	126.0	160.4
<i>PSUP</i> ( $10^{-1}$ hPa)	9864.0	9931.0	61.76	65.07	9824.0	9890.0	9904.0	9972.0
<i>QSUP</i> (kg/kg)	0.0076	0.0095	0.0022	0.0021	0.0061	0.0082	0.0091	0.0107
<i>USUP</i> (m/seg)	2.036	0.9897	3.352	2.37	-0.603	-0.710	4.436	2.469
<i>VSUP</i> (m/seg)	-1.067	0.5544	2.117	2.338	-2.263	-1.11	0.3433	2.142
<i>T850.00</i> ( $10^{-1}$ °C)	93.14	103.8	51.53	49.88	56.0	67.34	131.0	132.6
<i>A850.00</i> (m)	1525.0	1533.0	58.63	53.89	1485.0	1504.0	1570.0	1570.0
<i>Q850.00</i> (kg/kg)	0.0068	0.0053	0.0021	0.0020	0.0052	0.0039	0.0081	0.0067
<i>U850.00</i> (m/seg)	4.891	4.852	6.182	5.159	0.6946	1.323	8.608	7.815
<i>V850.00</i> (m/seg)	-1.947	0.615	6.546	5.541	-5.449	-2.885	2.5	4.301
<i>T500.00</i> ( $10^{-1}$ °C)	-157.5	-142.3	44.88	34.42	-185.0	-164.9	-127.0	-115.8
<i>A500.00</i> (m)	5728.0	5732.0	111.9	86.83	5650.0	5682.0	5810.0	5795.0
<i>Q500.00</i> (kg/kg)	0.0014	0.0014	6.6e-4	6.5e-4	9.1e-4	8.6e-4	0.0018	0.0018
<i>U500.00</i> (m/seg)	9.137	9.713	10.08	7.35	2.865	4.786	15.45	14.46
<i>V500.00</i> (m/seg)	-1.109	-0.640	10.03	7.865	-7.071	-4.977	5.705	4.45
<i>T85/50.00</i> ( $10^{-1}$ °C)	250.8	246.1	32.49	40.37	229.2	218.0	271.0	271.4
<i>A85/50.00</i> (m)	-4203	-4199	67.57	53.75	-4249	-4241	-4160	-4161

Tabla C.3: Momentos y cuartiles de las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en Verano y Otoño.

Variable	Test	En.	Feb.	Mar.	Abr.	Mayo	Jun.	Jul.	Ago.	Sep.	Oct.	Nov.	Dic.
<i>TMAX</i>	Test t	0	0.005	0	0	0	0	0.197	0.026	0	0.024	0	0
	Wilcoxon	0	0	0	0	0	0	0.005	0.001	0	0	0	0
	Test F	0	0	0	0	0	0	0.027	0	0	0.863	0	0
	Dispers.	0	0	0	0	0	0	0.218	0	0.001	0.576	0	0
	KS	0	0	0	0	0	0	0	0	0	0.001	0	0
<i>TMIN</i>	Test t	0	0	0.004	0.114	0.024	0.001	0.243	0.396	0.131	0	0.976	0
	Wilcoxon	0	0	0	0.031	0	0	0.014	0.074	0.013	0	0.348	0
	Test F	0.088	0.26	0.012	0.006	0.011	0.005	0	0	0	0	0	0.538
	Dispers.	0.736	0.805	0.008	0.06	0.066	0.188	0	0	0	0	0	0.374
	KS	0	0	0	0.016	0	0	0	0	0	0	0.001	0
<i>TDIF</i>	Test t	0	0	0	0	0	0	0.52	0.003	0	0	0	0.52
	Wilcoxon	0	0	0	0	0	0	0.274	0	0	0	0	0.307
	Test F	0.007	0	0	0	0	0.16	0.024	0.001	0.076	0.001	0	0.403
	Dispers.	0.165	0	0	0	0	0.045	0.145	0.014	0.083	0.083	0	0.209
	KS	0	0	0	0	0	0	0.091	0	0	0	0	0.167
<i>PSUP</i>	Test t	0.102	0.242	0	0	0	0	0.001	0.004	0	0	0	0.11
	Wilcoxon	0.006	0.068	0	0	0	0	0	0	0	0	0	0.007
	Test F	0.264	0.12	0.817	0.25	0.002	0.002	0	0	0.006	0.619	0.021	0.604
	Dispers.	0.96	0.854	0.925	0.379	0.002	0.026	0	0	0.006	0.252	0.238	0.28
	KS	0.014	0.089	0	0	0	0	0	0	0	0	0	0.028
<i>QSUP</i>	Test t	0	0	0	0	0	0	0	0	0	0	0	0
	Wilcoxon	0	0	0	0	0	0	0	0	0	0	0	0
	Test F	0.664	0.976	0.195	0	0.389	0.207	0.024	0.792	0.161	0.075	0.747	0.541
	Dispers.	0.435	0.387	0.788	0.009	0.185	0.984	0.444	0.856	0.572	0.578	0.216	0.105
	KS	0	0	0	0	0	0	0	0	0	0	0	0

Tabla C.4: Tests para comparar las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en superficie.

Variable	Test	En.	Feb.	Mar.	Abr.	Mayo	Jun.	Jul.	Ago.	Sep.	Oct.	Nov.	Dic.
T850.00	Test t	0.118	0.409	0.044	0.305	0	0.013	0.552	0.937	0.005	0.101	0.318	0.014
	Wilcoxon	0.028	0.091	0	0.226	0	0	0.091	0.741	0	0.003	0.058	0
	Test F	0	0	0	0.077	0.005	0	0.446	0	0.694	0.051	0	0
	Dispers.	0	0	0	0.004	0.002	0	0.018	0	0.73	0.046	0	0
	KS	0.001	0.001	0	0.06	0	0	0.001	0.005	0	0.003	0	0
A850.00	Test t	0.003	0	0.177	0.68	0.001	0	0	0	0.467	0.024	0.922	0.001
	Wilcoxon	0	0	0.001	0.496	0	0	0	0	0.982	0	0.739	0
	Test F	0.137	0.747	0.016	0.181	0.632	0.359	0.916	0.241	0	0.009	0.348	0.661
	Dispers.	0.653	0.249	0.311	0.26	0.257	0.059	0.889	0.915	0	0.009	0.588	0.401
	KS	0	0	0.003	0.634	0	0	0	0	0.06	0	0.923	0
Q850.00	Test t	0.322	0.026	0	0	0	0	0	0	0	0	0.001	0.752
	Wilcoxon	0.444	0.009	0	0	0	0	0	0	0	0	0	0.949
	Test F	0	0.004	0	0	0.016	0.497	0.706	0.455	0.717	0	0	0.025
	Dispers.	0.003	0.026	0	0	0.081	0.086	0.025	0.709	0.579	0.01	0.002	0.009
	KS	0.046	0.023	0	0	0	0	0	0	0	0	0.366	

Tabla C.5: Tests para comparar las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en la altura del geopotencial 850hPa.

Variable	Test	En.	Feb.	Mar.	Abr.	Mayo	Jun.	Jul.	Ago.	Sep.	Oct.	Nov.	Dic.
T500.00	Test t	0.019	0.047	0.018	0	0.041	0.006	0	0	0	0	0.043	0.025
	Wilcoxon	0.018	0.059	0	0	0	0	0	0	0	0	0.043	0.004
	Test F	0	0	0	0	0.234	0	0	0	0	0	0	0
	Dispers.	0	0.001	0.336	0.134	0.351	0.001	0	0	0	0.001	0	0
	KS	0.001	0.013	0.001	0	0.004	0	0	0	0	0	0	0
A500.00	Test t	0.001	0	0.035	0.268	0.002	0	0	0	0.486	0.138	0.405	0.001
	Wilcoxon	0	0	0	0.053	0	0	0	0	0.697	0.02	0.094	0
	Test F	0	0	0	0.009	0.008	0	0	0	0	0	0	0
	Dispers.	0	0	0.027	0.016	0.043	0.001	0.049	0.001	0	0	0	0
	KS	0	0	0	0.038	0	0	0	0	0	0	0	0
Q500.00	Test t	0.103	0.62	0.492	0.001	0.096	0.084	0.772	0.17	0.254	0.812	0.948	0.028
	Wilcoxon	0.085	0.616	0.704	0.002	0.008	0.042	0.576	0.229	0.355	0.458	0.991	0.007
	Test F	0.032	0.259	0.003	0.001	0	0.774	0.002	0.243	0.437	0.18	0.716	0.47
	Dispers.	0.045	0.253	0.04	0.065	0	0.4	0.092	0.506	0.326	0.76	0.991	0.418
	KS	0.018	0.6	0.472	0.007	0.001	0.025	0.388	0.524	0.37	0.62	0.853	0.051
T85/50.00	Test t	0.22	0	0	0	0	0	0.003	0.032	0.667	0.018	0.081	0.586
	Wilcoxon	0.073	0	0	0	0	0	0	0.003	0.894	0	0.005	0.868
	Test F	0	0	0.038	0.721	0.022	0.096	0.122	0	0	0	0.516	0
	Dispers.	0	0.004	0.136	0.811	0.022	0.432	0	0	0	0	0.682	0.002
	KS	0.015	0	0	0	0	0	0	0	0.004	0	0.008	0.254
A85/50.00	Test t	0.012	0.009	0.002	0.075	0.016	0.014	0.002	0	0.782	0.821	0.071	0.029
	Wilcoxon	0	0	0	0.006	0	0	0	0	0.509	0.509	0	0
	Test F	0	0	0	0.048	0.19	0	0	0.011	0	0	0	0
	Dispers.	0	0	0.049	0.428	0.211	0	0.507	0.439	0	0	0	0
	KS	0	0	0	0.007	0	0	0	0	0.002	0.053	0	0

Tabla C.6: Tests para comparar las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en la altura del geopotencial 500hPa, y diferencias de temperatura y altura entre ambos geopotenciales.

Variable	Test	En.	Feb.	Mar.	Abr.	Mayo	Jun.	Jul.	Ago.	Sep.	Oct.	Nov.	Dic.
<i>USUP</i>	Test t	0.26	0.794	0.002	0	0.073	0	0	0	0	0.108	0.024	0.255
	Wilcoxon	0.009	0.625	0	0	0.12	0	0	0	0	0.055	0.012	0.012
	Test F	0	0	0	0.222	0	0.001	0.001	0	0	0	0	0
	Dispers.	0	0	0	0.285	0.003	0.024	0	0	0	0	0	0
	KS	0	0.043	0	0	0.005	0	0	0	0	0	0	0
<i>VSUP</i>	Test t	0	0	0	0	0.061	0	0	0	0	0	0	0
	Wilcoxon	0	0	0	0	0.217	0	0	0	0	0	0	0
	Test F	0.545	0.313	0.165	0.002	0.078	0	0	0	0.001	0.621	0.279	0.292
	Dispers.	0.292	0.897	0.594	0.007	0	0	0	0	0	0.157	0.329	0.45
	KS	0	0	0	0	0	0	0	0	0	0	0	0
<i>U850.00</i>	Test t	0	0	0.002	0.553	0.779	0.225	0.015	0.947	0.71	0.762	0.872	0
	Wilcoxon	0	0	0	0.209	0.558	0.092	0.004	0.367	0.137	0.683	0.69	0
	Test F	0.703	0.905	0.001	0.321	0.754	0.031	0	0	0	0.011	0.283	0.122
	Dispers.	0.803	0.086	0.003	0.106	0.19	0.024	0	0	0	0.002	0.264	0.976
	KS	0	0	0	0.126	0.402	0.074	0	0.019	0.001	0.121	0.698	0
<i>V850.00</i>	Test t	0	0	0	0.005	0.065	0.095	0	0.043	0	0.226	0	0
	Wilcoxon	0	0	0	0.001	0	0.234	0	0.047	0	0.226	0	0
	Test F	0.006	0.934	0.735	0.605	0.631	0.013	0.09	0.28	0.002	0.004	0.03	0.003
	Dispers.	0.028	0.684	0.241	0.539	0.127	0.924	0.409	0.083	0.729	0.206	0.035	0.064
	KS	0	0	0	0.001	0	0.387	0.006	0.005	0	0.39	0	0
<i>U500.00</i>	Test t	0	0	0	0.014	0.061	0.015	0.382	0.042	0.296	0.556	0.936	0
	Wilcoxon	0	0	0	0	0	0	0.043	0.002	0.246	0.239	0.757	0
	Test F	0	0.002	0.095	0.084	0	0	0	0	0	0	0.002	0
	Dispers.	0	0.182	0.466	0.274	0	0	0	0	0	0	0.284	0.003
	KS	0	0	0	0	0	0	0	0	0.001	0.015	0.758	0
<i>V500.00</i>	Test t	0.043	0	0.001	0.346	0.001	0.08	0.24	0.84	0.922	0.251	0.029	0
	Wilcoxon	0.022	0	0	0.187	0	0.007	0.013	0.979	0.931	0.243	0.002	0
	Test F	0	0.048	0.136	0.263	0.701	0	0	0	0	0.001	0.007	0.013
	Dispers.	0	0.334	0.571	0.751	0.34	0.015	0.014	0.004	0	0.034	0.003	0.001
	KS	0.005	0.001	0	0.315	0	0.002	0.003	0.154	0.094	0.04	0	0

Tabla C.7: Tests para comparar las componentes de viento observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes.

Variable	Test	En.	Feb.	Mar.	Abr.	Mayo	Jun.	Jul.	Ago.	Sep.	Oct.	Nov.	Dic.
<i>TMAX</i>	Test t	0.67	0.252	0.506	0.49	0.187	0.839	0.475	0.562	0.572	0.475	0.544	0.986
	Wilcoxon	0.43	0.321	0.237	0.185	0.019	0.674	0.588	0.316	0.595	0.48	0.369	0.573
	Test F	0	0	0	0	0	0	0.405	0	0	0.092	0	0
	Dispers.	0	0	0	0	0	0	0.554	0	0	0.028	0	0
	KS	0	0.001	0	0	0	0.002	0.279	0.001	0.006	0.28	0.042	0
<i>TMIN</i>	Test t	0.376	0.383	0.664	0.476	0.259	0.809	0.93	0.953	0.863	0.826	0.965	0.541
	Wilcoxon	0.331	0.162	0.487	0.394	0.039	0.839	0.939	0.537	0.547	0.716	0.347	0.368
	Test F	0.103	0.248	0.005	0.036	0	0.001	0	0	0	0	0	0.67
	Dispers.	0.834	0.902	0.002	0.121	0	0.02	0	0	0	0	0	0.174
	KS	0.49	0.133	0.184	0.116	0.005	0.215	0	0	0	0.004	0	0.196
<i>TDIF</i>	Test t	0.592	0.852	0.733	0.837	0.572	0.967	0.273	0.208	0.245	0.566	0.636	0.441
	Wilcoxon	0.427	0.656	0.909	0.405	0.806	0.898	0.272	0.21	0.045	0.866	0.29	0.33
	Test F	0.009	0	0	0	0	0.058	0.067	0.001	0.025	0.001	0	0.7
	Dispers.	0.18	0.001	0	0	0	0.013	0.235	0.01	0.076	0.088	0	0.492
	KS	0.574	0.362	0.018	0.043	0.018	0.344	0.213	0.087	0.017	0.19	0.013	0.309
<i>PSUP</i>	Test t	0.695	0.63	0.83	0.738	0.747	0.989	0.944	0.753	0.701	0.759	0.532	0.559
	Wilcoxon	0.65	0.301	0.831	0.573	0.131	0.792	0.873	0.479	0.947	0.373	0.139	0.186
	Test F	0.244	0.114	0.896	0.323	0.002	0.001	0	0	0.017	0.588	0.013	0.548
	Dispers.	0.859	0.744	0.515	0.211	0.002	0.034	0.001	0	0.009	0.235	0.134	0.264
	KS	0.802	0.23	0.83	0.667	0.007	0.474	0.169	0.02	0.598	0.161	0.032	0.161
<i>QSUP</i>	Test t	0.975	0.193	0.149	0.057	0.045	0.307	0.922	0.481	0.743	0.418	0.109	0.305
	Wilcoxon	0.308	0.052	0.1	0.009	0.009	0.099	0.451	0.31	0.378	0.813	0.006	0.471
	Test F	0.545	0.864	0.22	0	0.129	0.185	0.003	0.685	0.631	0.139	0.399	0.495
	Dispers.	0.397	0.439	0.775	0.004	0.04	0.723	0.36	0.926	0.813	0.299	0.55	0.14
	KS	0.181	0.061	0.181	0.006	0.045	0.066	0.409	0.73	0.516	0.674	0.014	0.599

Tabla C.8: Tests para comparar las anomalías de las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en superficie.

Variable	Test	En.	Feb.	Mar.	Abr.	Mayo	Jun.	Jul.	Ago.	Sep.	Oct.	Nov.	Dic.
T850.00	Test t	0.762	0.327	0.392	0.183	0.08	0.972	0.51	0.599	0.455	0.423	0.756	0.958
	Wilcoxon	0.643	0.398	0.054	0.07	0	0.202	0.732	0.335	0.27	0.518	0.433	0.823
	Test F	0	0	0	0.014	0.007	0	0.404	0	0.218	0.002	0	0
	Dispers.	0	0	0	0	0.003	0	0.003	0	0.216	0.002	0	0
	KS	0.026	0.001	0.002	0.008	0	0.001	0.092	0.006	0.146	0.122	0.001	0.002
A850.00	Test t	0.773	0.816	0.928	0.939	0.756	0.853	0.873	0.556	0.47	0.676	0.546	0.514
	Wilcoxon	0.895	0.518	0.552	0.944	0.956	0.697	0.771	0.362	0.906	0.434	0.205	0.214
	Test F	0.137	0.754	0.024	0.184	0.899	0.298	0.937	0.153	0	0.009	0.296	0.648
	Dispers.	0.58	0.221	0.485	0.406	0.47	0.16	0.92	0.734	0	0.014	0.873	0.369
	KS	0.623	0.505	0.783	0.928	0.958	0.576	0.866	0.684	0.074	0.157	0.542	0.327
Q850.00	Test t	0.614	0.26	0.388	0.339	0.37	0.904	0.953	0.908	0.862	0.501	0.396	0.968
	Wilcoxon	0.807	0.248	0.304	0.268	0.248	0.786	0.922	0.761	0.878	0.513	0.257	0.571
	Test F	0	0.003	0	0	0.001	0.687	0.849	0.656	0.306	0	0	0.037
	Dispers.	0.003	0.021	0	0	0.003	0.33	0.142	0.61	0.793	0.014	0.001	0.006
	KS	0.13	0.136	0.04	0.056	0.097	0.493	0.258	0.577	0.94	0.25	0.039	0.175

Tabla C.9: Tests para comparar las anomalías de las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en la altura del geopotencial 850hPa.

Variable	Test	En.	Feb.	Mar.	Abr.	Mayo	Jun.	Jul.	Ag.	Sep.	Oct.	Nov.	Dic.
T500.00	Test t	0.845	0.579	0.294	0.24	0.191	0.796	0.938	0.838	0.717	0.985	0.918	0.908
	Wilcoxon	0.256	0.693	0.026	0.111	0.016	0.763	0.603	0.896	0.765	0.385	0.13	0.738
	Test F	0	0	0	0	0.549	0	0	0	0	0	0	0
	Dispers.	0	0	0.239	0.023	0.98	0	0	0	0	0.001	0	0
A500.00	KS	0.003	0.14	0.023	0.146	0.063	0.184	0.038	0.052	0.002	0.056	0.006	0.029
	Test t	0.939	0.806	0.68	0.469	0.298	0.826	0.761	0.523	0.342	0.622	0.692	0.657
	Wilcoxon	0.592	0.771	0.059	0.217	0.057	0.732	0.584	0.221	0.879	0.494	0.692	0.382
	Test F	0	0	0	0.008	0.07	0	0	0	0	0	0	0
Q500.00	Dispers.	0	0	0.005	0.006	0.338	0.001	0.146	0	0	0	0	0
	KS	0.038	0.039	0.013	0.101	0.055	0.329	0.321	0.03	0.001	0.012	0.005	0.005
	Test t	0.941	0.565	0.346	0.353	0.374	0.848	0.807	0.313	0.429	0.915	0.756	0.677
	Wilcoxon	0.939	0.549	0.163	0.557	0.08	0.961	0.605	0.457	0.62	0.754	0.641	0.456
T85/50.00	Test F	0.029	0.257	0.004	0.002	0	0.877	0.002	0.257	0.739	0.214	0.578	0.657
	Dispers.	0.045	0.249	0.046	0.074	0	0.322	0.068	0.499	0.527	0.744	0.707	0.527
	KS	0.248	0.6	0.051	0.562	0.013	0.651	0.413	0.874	0.598	0.731	0.603	0.645
	Test t	0.734	0.524	0.922	0.611	0.372	0.822	0.438	0.521	0.621	0.477	0.691	0.902
A85/50.00	Wilcoxon	0.428	0.931	0.609	0.738	0.036	0.127	0.622	0.323	0.908	0.268	0.804	0.539
	Test F	0	0	0.038	0.69	0.025	0.1	0.189	0	0	0	0.487	0
	Dispers.	0.001	0.001	0.17	0.645	0.025	0.418	0	0	0	0	0.765	0.001
	KS	0.223	0.411	0.398	0.208	0.036	0.031	0.023	0	0.002	0.015	0.925	0.165
A85/50.00	Test t	0.788	0.417	0.237	0.151	0.106	0.852	0.751	0.812	0.367	0.605	0.996	0.932
	Wilcoxon	0.265	0.835	0.006	0.032	0.003	0.396	0.657	0.527	0.496	0.34	0.254	0.785
	Test F	0	0	0	0.01	0.382	0	0	0.017	0	0	0	0
	Dispers.	0	0	0.014	0.081	0.826	0	0.517	0.644	0	0	0	0
	KS	0.001	0.038	0.001	0.062	0.007	0.069	0.447	0.833	0.002	0.002	0	0.002

Tabla C.10: Tests para comparar las anomalías de las variables observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes, en el geopotencial 500hPa, y diferencias de temperatura y altura entre ambos geopotenciales.

Variable	Test	En.	Feb.	Mar.	Abr.	Mayo	Jun.	Jul.	Ago.	Sep.	Oct.	Nov.	Dic.
<i>USUP</i>	Test t	0.587	0.824	0.88	0.853	0.33	0.205	0.75	0.325	0.813	0.632	0.227	0.293
	Wilcoxon	0.694	0.669	0.992	0.946	0.016	0.063	0.268	0.158	0.856	0.314	0.264	0.014
	Test F	0	0	0	0.243	0	0	0	0	0	0	0	0
	Dispers.	0	0	0	0.295	0.003	0.008	0	0	0	0	0	0
	KS	0	0.073	0.041	0.89	0.003	0.063	0	0	0.001	0	0.001	0
<i>VSUP</i>	Test t	0.924	0.901	0.713	0.569	0.277	0.664	0.922	0.578	0.681	0.602	0.346	0.832
	Wilcoxon	0.171	0.322	0.908	0.566	0.019	0.898	0.879	0.352	0.548	0.205	0.948	0.016
	Test F	0.51	0.385	0.172	0.002	0.068	0	0	0	0.001	0.617	0.302	0.257
	Dispers.	0.248	0.876	0.638	0.005	0	0	0	0	0	0.141	0.307	0.643
	KS	0.003	0.033	0.679	0.054	0	0.005	0.001	0.001	0.007	0.125	0.062	0
<i>U850.00</i>	Test t	0.621	0.097	0.403	0.472	0.339	0.696	0.385	0.236	0.637	0.688	0.257	0.291
	Wilcoxon	0.493	0.036	0.181	0.156	0.108	0.541	0.386	0.014	0.075	0.578	0.059	0.128
	Test F	0.775	0.904	0.001	0.351	0.801	0.032	0	0	0	0.009	0.308	0.076
	Dispers.	0.877	0.112	0.004	0.105	0.194	0.03	0	0	0	0.002	0.285	0.728
	KS	0.828	0.074	0.106	0.129	0.057	0.339	0.023	0	0	0.076	0.123	0.276
<i>V850.00</i>	Test t	0.849	0.412	0.538	0.457	0.256	0.692	0.431	0.239	0.278	0.291	0.239	0.554
	Wilcoxon	0.345	0.535	0.137	0.736	0.003	0.521	0.696	0.023	0.562	0.025	0.226	0.123
	Test F	0.006	0.868	0.741	0.635	0.677	0.012	0.086	0.288	0.002	0.003	0.036	0.003
	Dispers.	0.03	0.778	0.229	0.697	0.098	0.953	0.427	0.085	0.702	0.24	0.04	0.067
	KS	0.161	0.4	0.081	0.226	0	0.546	0.113	0.007	0.121	0.013	0.197	0.145
<i>U500.00</i>	Test t	0.924	0.412	0.559	0.565	0.749	0.509	0.342	0.343	0.645	0.999	0.711	0.602
	Wilcoxon	0.977	0.254	0.071	0.591	0.259	0.22	0.519	0.159	0.152	0.854	0.846	0.16
	Test F	0	0.002	0.089	0.063	0	0	0	0	0	0	0.002	0
	Dispers.	0	0.173	0.403	0.229	0	0	0	0	0	0	0.252	0
	KS	0.114	0.473	0.009	0.438	0.018	0.02	0.001	0.017	0.001	0.068	0.638	0.041
<i>V500.00</i>	Test t	0.442	0.268	0.484	0.477	0.384	0.321	0.547	0.821	0.875	0.798	0.531	0.971
	Wilcoxon	0.115	0.256	0.456	0.313	0.183	0.106	0.961	0.974	0.66	0.927	0.295	0.728
	Test F	0	0.029	0.144	0.347	0.644	0	0	0	0	0.001	0.009	0.01
	Dispers.	0	0.262	0.541	0.724	0.342	0.025	0.017	0.003	0	0.023	0.007	0.001
	KS	0.011	0.44	0.798	0.611	0.167	0.104	0.134	0.172	0.119	0.085	0.224	0.056

Tabla C.11: Tests para comparar las anomalías de las componentes de viento observadas y generadas por CGCM1 para el periodo 1990-2000, en cada mes.

## **C.2** Downscaling con el modelo *Down1*

Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-1.855	0.1005	-18.470
$S1$	-0.3067	0.1016	-3.017
$C1$	0.4637	0.1023	4.532
$S2$	-0.5008	0.09582	-5.226
$C2$	-0.03676	0.09891	-0.3716
$S3$	0.3163	0.09683	3.267
$C3$	0.2893	0.09728	2.974
$S4$	0.1937	0.09675	2.002
$C4$	-0.2132	0.09518	-2.241
$z.TDIF_t$	-0.02983	0.003144	-9.490
$z.TMIN_t$	-0.02909	0.004051	-7.181
$z.PSUP_t$	-0.01967	0.005029	-3.911
$z.QSUP_t$	1058.000	84.340	12.540
$z.QSUP_t^2$	-9.084e4	1.972e4	-4.607
$z.QSUP_{t-1}$	-105.900	52.270	-2.026
$z.A850.00_{t+1}$	0.01433	0.003446	4.160
$z.A850.00_t$	0.01132	0.004378	2.585
$z.A500.00_{t+1}$	-0.01781	0.00214	-8.321
$z.A500.00_{t+1}^2$	-2.158e-5	5.695e-6	-3.789
$z.Q500.00_t$	573.300	143.200	4.004
$z.Q500.00_{t+1}$	613.500	149.000	4.119

Tabla C.12: Modelo para la ocurrencia de *Down1*.

		Deviance	Gr. lib.
Modelo nulo		2451.36	2258
Modelo ajustado		1444.63	2237
AIC:	1486.63	BIC:	1606.8
Estad. HL	14.17	p-valor	0.08
% variabilidad explicada por modelo			44.16
Autocorrelación orden 1 en residuos			0.07
% días bien clasificados (0.5)		Anual	86.4
Primav.	Verano	Otoño	Invierno
86.89	87.94	86.39	84.29
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	95.53	84.17
	Húmedo	52.94	73.84
%NAS		Anual	51.65
Primav.	Verano	Otoño	Invierno
50.66	41.03	58.06	52.78
% días bien clasificados (frec. día)		Anual	79.94
Primav.	Verano	Otoño	Invierno
85.31	77.8	78.88	77.63
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	82.39	63.67
	Húmedo	77.16	87.34
%NAS		Anual	48.7
Primav.	Verano	Otoño	Invierno
54.1	36.82	52.36	50.61
Índice relativo de Brier		Anual	44.19
Primav.	Verano	Otoño	Invierno
48.88	35.46	47.24	41.04
Días de precipitación observados y predichos por meses			
Coef. correlación	0.9797	Coef. eficiencia	0.9557
Índice de acuerdo	0.9878	% medio error	0.6882

Tabla C.13: Medidas de bondad de ajuste del modelo de ocurrencia de *Down1* (1990-1997).

AIC:	489.39	BIC:	584.44
Estad. HL	11.17	p-valor	0.19
% variabilidad explicada por modelo			41.25
Autocorrelación orden 1 en residuos			0.07
% días bien clasificados (0.5)		Anual	86.68
Primav.	Verano	Otoño	Invierno
82.61	89.6	88.89	87.94
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	97.51	87.5
	Húmedo	48.39	65
%NAS		Anual	48
Primav.	Verano	Otoño	Invierno
48.05	41.94	55	48.94
% días bien clasificados (frec. día)		Anual	83.31
Primav.	Verano	Otoño	Invierno
80	87.86	77.78	85.43
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	89.82	64.77
	Húmedo	68.82	85
%NAS		Anual	50.22
Primav.	Verano	Otoño	Invierno
53.54	50	37.93	50.85
Índice relativo de Brier		Anual	41.34
Primav.	Verano	Otoño	Invierno
40.37	42.26	37.25	40.38
Días de precipitación observados y predichos por meses			
Coef. correlación	0.7019	Coef. eficiencia	0.3547
Índice de acuerdo	0.8119	% medio error	8.029

Tabla C.14: Medidas de bondad de ajuste del modelo de ocurrencia de *Down1*, periodo de validación (1998-2000).

Periodo de validación, 1998-2000

Mes	$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	35.95	6	7	-	-
2	20.76	4.55	5.82	0.904	0.562
3	12.4	5	7	-	-
4	26.1	10.52	11.12	0.617	0.193
5	12	3	6.5	-	-
6	18.63	5.38	7.46	0.899	0.22
7	6.4	2	3	-	-
8	7.78	2.17	3.04	1	0.57
9	8	4	5	-	-
10	8.91	2.92	3.88	0.95	0.455
11	18.6	4.5	8	-	-
12	30.8	8.9	11.7	0.529	0.193
13	12.8	6	2	-	-
14	12.08	5.08	3.88	0.279	0.224
15	24.1	8	9.25	-	-
16	14.81	8.43	5.58	0.925	0.503
17	9.4	5	3.5	-	-
18	10.09	5.25	4.55	0.94	0.92
19	4	2.5	1.75	-	-
20	7.49	4.28	2.59	0.494	0.167
21	9	6	6.5	-	-
22	9.78	5.22	4.53	0.915	0.684
23	10.65	3.5	4.5	-	-
24	13.12	6.48	5.45	0.798	0.314

Periodo de estimación, 1990-1997

Mes	$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	16.8	4	7	-	-
2	18.04	2.65	4.54	0.39	0.093
3	13.4	5	6	-	-
4	21.71	3.65	5.26	0.408	0.128
5	25.05	3.5	9	-	-
6	27.49	4.6	8.64	0.995	0.957
7	11.45	5.5	6	-	-
8	15.83	3.98	6.25	0.684	0.465
9	25.05	3	3.5	-	-
10	16.86	2.95	4.39	0.997	0.617
11	16	3	6	-	-
12	21.66	3.08	6.18	0.783	0.545
13	19	6	11	-	-
14	17.21	6.18	6.11	0.449	0.533
15	15.8	5	5	-	-
16	17.28	4.6	7.39	0.339	0.335
17	11	5	5	-	-
18	12.92	3.92	5.5	0.71	0.848
19	13	3	6.5	-	-
20	12.28	2.45	3.55	0.721	0.331
21	9.9	2	4	-	-
22	10.95	2.38	3.81	1	0.79
23	10.7	3	4.25	-	-
24	15.49	2.88	4.28	0.994	0.729

Tabla C.15: Percentiles de la longitud de racha seca observada y simulada por el modelo de ocurrencia de *Down1*, para cada mes, usando los datos observados en Zaragoza, en los periodos de estimación y validación.

Periodo de validación, 1998-2000

	$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
	2	1.5	1	-	-
	5.68	1.45	1.31	0.698	0.648
	3	2.5	1	-	-
	2.16	1.3	0.51	0.076	0.003
	4.45	1	1	-	-
	2.63	1.15	0.57	0.977	0.392
	4.6	2	2	-	-
	3.23	1.1	0.94	0.091	0.015
	6.2	2	1	-	-
	3.46	1.38	1.1	0.828	0.357
	2	1	0.5	-	-
	3.02	1.05	0.56	0.972	0.821
	2.55	1	0.75	-	-
	1.58	1.02	0.19	0.916	0.107
	2	1	0	-	-
	1.38	1.05	0.14	1	0.53
	2	1	1	-	-
	2.45	1.52	0.84	1	0.577
	2	1	1	-	-
	2.35	1.4	0.46	0.995	0.502
	1.75	1	0	-	-
	2.55	1.27	0.7	1	0.47
	3	1	1	-	-
	2.54	1.2	0.49	1	0.523

Periodo de estimación, 1990-1997

Mes	$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	Obs. 5.85	1	2.25	-	-
	Simul. 4.69	1.1	1.1	0.749	0.699
2	Obs. 3	1	1	-	-
	Simul. 3.11	1.1	1	0.999	0.481
3	Obs. 3	1	1	-	-
	Simul. 3.86	1.05	0.88	0.997	0.565
4	Obs. 5	2	1	-	-
	Simul. 3.74	1.05	0.96	0.481	0.122
5	Obs. 5.35	1	2	-	-
	Simul. 5.13	1.38	1.48	1	0.868
6	Obs. 3	1	1	-	-
	Simul. 2.56	1	0.59	0.405	0.07
7	Obs. 3	1	0.5	-	-
	Simul. 2.24	1	0.56	0.977	0.718
8	Obs. 3	1.5	1	-	-
	Simul. 2.6	1	0.66	0.285	0.028
9	Obs. 3	1	1	-	-
	Simul. 3.07	1.1	0.94	1	0.793
10	Obs. 4	2	2	-	-
	Simul. 4.51	1.42	1.31	0.999	0.567
11	Obs. 3	1	1	-	-
	Simul. 3.68	1.23	1.1	1	0.852
12	Obs. 5	1	1	-	-
	Simul. 4.94	1.1	1.27	0.914	0.455

Tabla C.16: Percentiles de la longitud de racha húmeda observada y simulada por el modelo de ocurrencia de *Down*<sub>1</sub>, para cada mes, usando los datos observados en Zaragoza, en los periodos de estimación y validación.

Término	Coeficiente	Error std.	Estadístico $t$
$\beta_0$	2.614	0.08247	31.690
$S1$	-0.06155	0.07676	-0.802
$C1$	0.01305	0.08115	0.1608
$S2$	-0.1219	0.07153	-1.704
$C2$	0.04961	0.07732	0.6416
$S3$	0.1266	0.07312	1.732
$C3$	0.1942	0.07378	2.633
$S4$	0.1617	0.07423	2.178
$C4$	-0.05488	0.07254	-0.7565
$z.TDIF_t$	-0.01714	0.002004	-8.553
$z.TMIN_t$	-0.02204	0.002527	-8.722
$z.PSUP_t$	-0.01486	0.002321	-6.405
$z.QSUP_t$	325.500	45.010	7.233
$z.A850.00_t$	0.01354	0.002704	5.007
Parámetro de dispersión: 1.415			

Tabla C.17: Modelo de cantidad de *Down1*.

		Deviance	Gr. lib.	
Modelo nulo		1030	567	
Modelo ajustado		740.11	553	
AIC:	5784.25	BIC:	5845.01	
% variabilidad explicada por modelo		29.86		
% variabilidad explicada por el modelo por estaciones				
Primav.	Verano	Otoño	Invierno	
40.27	32.45	18.35	31	
Autocorrelación orden 1 en residuos		-0.01		
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.8537	Coef. eficiencia	0.7085	
Índice de acuerdo	0.8957	% medio error	2.409	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
4.938	16.400	53.970	15.340	9.347
% días clasificados en los intervalos, si el día anterior seco				
6.289	18.550	51.890	13.840	9.434
% días clasificados en los intervalos, si el día anterior llovió				
3.213	13.650	56.630	17.270	9.237
% días ( $q_{0.10}, q_{0.90}$ )	Primav.	Verano	Otoño	Invierno
	85.270	88.570	85.030	84.940

Tabla C.18: Medidas de bondad de ajuste del modelo de cantidad de *Down1* (1990-1997).

AIC:	1683.92	BIC:	1728.3	
% variabilidad explicada por modelo			34.78	
% variabilidad explicada por el modelo por estaciones				
Primav.	Verano	Otoño	Invierno	
47.16	0	14.43	0	
Autocorrelación orden 1 en residuos			0.04	
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.5905	Coef. eficiencia	-1.188	
Índice de acuerdo	0.6225	% medio error	42.070	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
6.250	25.000	50.570	11.360	6.818
% días clasificados en los intervalos, si el día anterior seco				
4.762	26.670	51.430	12.380	4.762
% días clasificados en los intervalos, si el día anterior llovió				
8.451	22.540	49.300	9.859	9.859
% días ( $q_{0.10}, q_{0.90}$ )	Primav.	Verano	Otoño	Invierno
	87.800	87.500	100.000	78.570

Tabla C.19: Medidas de bondad de ajuste del modelo de cantidad de *Down1*, periodo de validación (1998-2000).

Periodo de validación, 1998-2000

	$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1 Obs.	84.75	8.5	39.25	-	-
Mes 1 Simul.	142.27	18.64	43.61	0.324	0.264
Mes 2 Obs.	81	6	25	-	-
Mes 2 Simul.	139.2	17.24	40.62	0.314	0.141
Mes 3 Obs.	93	13.5	40	-	-
Mes 3 Simul.	148.45	21.31	46.15	0.679	0.429
Mes 4 Obs.	132.25	9.5	20.25	-	-
Mes 4 Simul.	119.78	16.98	37.2	0.237	0.45
Mes 5 Obs.	191	14	38	-	-
Mes 5 Simul.	112.84	16.37	37.66	0.891	0.992
Mes 6 Obs.	80.2	32	50.5	-	-
Mes 6 Simul.	123.15	17.79	40.47	0.598	0.461
Mes 7 Obs.	120.55	13.5	38.25	-	-
Mes 7 Simul.	159.95	17.63	41.8	0.447	0.705
Mes 8 Obs.	89.8	9	18	-	-
Mes 8 Simul.	126.89	19.22	34.27	0.092	0.134
Mes 9 Obs.	74.8	18.5	39.75	-	-
Mes 9 Simul.	100.92	14.67	34.34	0.762	0.572
Mes 10 Obs.	86.75	17	49.75	-	-
Mes 10 Simul.	113.9	14.52	33.48	0.849	0.823
Mes 11 Obs.	104.5	7	31.5	-	-
Mes 11 Simul.	157.11	15.26	44.7	0.511	0.356
Mes 12 Obs.	56.4	7	12	-	-
Mes 12 Simul.	144.03	15.67	38.83	0.186	0.147

Periodo de estimación, 1990-1997

	$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1 Obs.	107.8	15	54.5	-	-
Mes 1 Simul.	136.41	16.35	38.47	0.678	0.912
Mes 2 Obs.	90	21.5	34.75	-	-
Mes 2 Simul.	126.96	19.94	39.63	0.835	0.903
Mes 3 Obs.	64	14	22	-	-
Mes 3 Simul.	124.55	17.78	42.3	0.355	0.454
Mes 4 Obs.	216	26	61	-	-
Mes 4 Simul.	119.1	16.13	35.66	0.102	0.051
Mes 5 Obs.	159.5	24	44.5	-	-
Mes 5 Simul.	130.05	16.78	38.38	0.047	0.025
Mes 6 Obs.	144.8	21	28	-	-
Mes 6 Simul.	132.06	17.6	37.59	0.5	0.439
Mes 7 Obs.	98.65	16	36	-	-
Mes 7 Simul.	114.95	17.81	33.63	0.98	0.943
Mes 8 Obs.	122.5	12	27.5	-	-
Mes 8 Simul.	132.7	17.23	41.06	0.42	0.415
Mes 9 Obs.	255.5	16	56	-	-
Mes 9 Simul.	133.05	17.53	41.8	0.384	0.642
Mes 10 Obs.	144.6	22	33	-	-
Mes 10 Simul.	124.21	16.07	36.93	0.27	0.357
Mes 11 Obs.	98.1	11	28.75	-	-
Mes 11 Simul.	149.34	18.59	41.73	0.177	0.162
Mes 12 Obs.	107.25	15.5	26.5	-	-
Mes 12 Simul.	142.26	17.66	39.03	0.171	0.248

Tabla C.20: Percentiles de las cantidades observadas y simuladas por el modelo *Down1*, usando los datos en los días de lluvia observados en Zaragoza.

		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1	Obs.	18	5	7	–	–
	Sim. obs.	19.08	3.12	5.41	0.313	0.088
	Sim. CGCM1	14.15	3.35	4.88	0.352	0.105
Mes 2	Obs.	13.55	5	6.5	–	–
	Sim. obs.	28.18	4.1	6.82	0.884	0.471
	Sim. CGCM1	22.61	4.68	7.82	0.856	0.716
Mes 3	Obs.	21	3	7.5	–	–
	Sim. obs.	25.66	4.92	8.78	0.898	0.459
	Sim. CGCM1	27.68	7.08	10.51	0.115	0.016
Mes 4	Obs.	9.4	3	6	–	–
	Sim. obs.	14.17	3.1	5.08	0.934	0.955
	Sim. CGCM1	15.5	4.68	5.82	0.481	0.062
Mes 5	Obs.	20.2	3	4	–	–
	Sim. obs.	14.18	2.95	4.18	0.959	0.432
	Sim. CGCM1	18.86	4.03	5.91	0.617	0.222
Mes 6	Obs.	18.8	4	8	–	–
	Sim. obs.	24.91	3.78	8.06	0.942	0.548
	Sim. CGCM1	24.57	5.88	9.04	0.061	0.068
Mes 7	Obs.	17.65	6	8.5	–	–
	Sim. obs.	17	6.08	6.25	0.623	0.356
	Sim. CGCM1	26.7	6.32	9.3	0.422	0.734
Mes 8	Obs.	23	5	8	–	–
	Sim. obs.	18.09	4.92	7.6	0.288	0.206
	Sim. CGCM1	16.7	4	5.32	0.134	0.031
Mes 9	Obs.	10.45	5	5	–	–
	Sim. obs.	13.01	3.82	5.55	0.939	0.831
	Sim. CGCM1	13.71	2.98	4.95	0.233	0.188
Mes 10	Obs.	11.8	3	4	–	–
	Sim. obs.	11.95	2.58	3.71	0.956	0.551
	Sim. CGCM1	12	2.95	4.74	0.999	0.999
Mes 11	Obs.	9.6	2	5	–	–
	Sim. obs.	10.99	2.5	4.1	1	0.934
	Sim. CGCM1	13.66	3	4.85	0.676	0.31
Mes 12	Obs.	11.1	3	5	–	–
	Sim. obs.	15.49	3.05	5.11	0.956	0.607
	Sim. CGCM1	11.92	2.9	4.18	0.818	0.651

Tabla C.21: Percentiles de la longitud de racha seca observada y simulada por el modelo *Down1*, para cada mes, usando los datos observados en Zaragoza y los generados por CGCM1 para el periodo 1990-2000.

		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1	Obs.	5.35	1	1	–	–
	Sim. obs.	5.27	1.1	1.24	1	0.925
	Sim. CGCM1	3.53	1	1	0.749	0.349
Mes 2	Obs.	3	2	1.5	–	–
	Sim. obs.	3.04	1.05	0.95	0.546	0.055
	Sim. CGCM1	2.83	1.05	0.79	0.1	0.003
Mes 3	Obs.	3.5	1	1	–	–
	Sim. obs.	3.55	1.05	0.81	0.945	0.328
	Sim. CGCM1	2.27	1	0.29	0.15	0.004
Mes 4	Obs.	5	2	1.75	–	–
	Sim. obs.	3.75	1.05	0.92	0.028	0.006
	Sim. CGCM1	3.15	1	0.91	0.01	0
Mes 5	Obs.	6.4	2	2	–	–
	Sim. obs.	4.75	1.32	1.34	1	0.513
	Sim. CGCM1	3.71	1	0.99	0.294	0.025
Mes 6	Obs.	2.45	1	1	–	–
	Sim. obs.	2.84	1	0.6	0.667	0.194
	Sim. CGCM1	3.1	1	0.57	0.796	0.287
Mes 7	Obs.	3	1	1	–	–
	Sim. obs.	2.18	1	0.38	0.961	0.384
	Sim. CGCM1	2.97	1	0.69	1	0.892
Mes 8	Obs.	3	1	1	–	–
	Sim. obs.	2.51	1	0.6	0.469	0.058
	Sim. CGCM1	3.45	1	0.96	0.999	0.558
Mes 9	Obs.	3	1	1	–	–
	Sim. obs.	3.06	1.1	0.98	1	0.92
	Sim. CGCM1	4.36	1.1	1.12	0.71	0.359
Mes 10	Obs.	4	2	1	–	–
	Sim. obs.	4.43	1.35	1.18	1	0.58
	Sim. CGCM1	5.05	1.15	1.44	0.983	0.63
Mes 11	Obs.	3	1	1	–	–
	Sim. obs.	3.64	1.15	1.06	1	0.646
	Sim. CGCM1	4.49	1.23	1.2	0.978	0.381
Mes 12	Obs.	4.55	1	1	–	–
	Sim. obs.	4.65	1.05	1.18	0.995	0.615
	Sim. CGCM1	3.32	1	0.98	0.586	0.945

Tabla C.22: Percentiles de la longitud de racha húmeda observada y simulada por el modelo *Down1*, para cada mes, usando los datos observados en Zaragoza y los generados por CGCM1 para el periodo 1990-2000.

		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1	Obs.	155.95	18	47	–	–
	Sim. obs.	122.64	16.59	34.71	0.103	0.166
	Sim. CGCM1	98.27	13.86	31.68	0.006	0.001
Mes 2	Obs.	126.2	17	37	–	–
	Sim. obs.	114.55	15	32.54	0.05	0.087
	Sim. CGCM1	65.56	9.71	21.2	0	0
Mes 3	Obs.	157.8	20	40	–	–
	Sim. obs.	110.49	14.41	29.09	0.003	0.001
	Sim. CGCM1	44.51	7.19	13.16	0	0
Mes 4	Obs.	135.4	15	36.75	–	–
	Sim. obs.	196.35	24.51	56.93	0.002	0.001
	Sim. CGCM1	81.62	12.2	28.46	0.052	0.054
Mes 5	Obs.	125.4	15	30	–	–
	Sim. obs.	181.76	23.33	48.39	0	0
	Sim. CGCM1	94.68	15.4	31.37	0.105	0.595
Mes 6	Obs.	132.7	12	36.5	–	–
	Sim. obs.	170.23	18.65	44.92	0.03	0.047
	Sim. CGCM1	87.75	11.87	27.18	0.026	0.044
Mes 7	Obs.	140.05	13.5	31	–	–
	Sim. obs.	141.91	20.59	40.47	0.004	0.003
	Sim. CGCM1	103.08	14.58	31.56	0.12	0.83
Mes 8	Obs.	121.85	16	35.25	–	–
	Sim. obs.	160.2	17.8	37.97	0.32	0.359
	Sim. CGCM1	136.59	18.21	41.42	0.098	0.192
Mes 9	Obs.	142.2	15	36	–	–
	Sim. obs.	153.3	17.39	44.69	0.158	0.198
	Sim. CGCM1	105.18	14.74	34.89	0.028	0.525
Mes 10	Obs.	157	18	40.75	–	–
	Sim. obs.	106.47	16.5	35.65	0.056	0.244
	Sim. CGCM1	95.53	13.74	30.64	0.014	0.008
Mes 11	Obs.	122.9	14.5	35	–	–
	Sim. obs.	106	11.75	26.89	0.011	0.003
	Sim. CGCM1	72.62	11.48	23.22	0.001	0
Mes 12	Obs.	134.6	16	34	–	–
	Sim. obs.	108.8	13.69	29.68	0.01	0.011
	Sim. CGCM1	65.02	10.64	20.6	0	0

Tabla C.23: Percentiles de las cantidades observadas y simuladas por el modelo *Down1*, para cada mes, usando los datos observados y los generados por CGCM1 para 1990-2000.

### **C.3 Búsqueda de un modelo estadístico para el downscaling**

Modelo <i>Down1</i> en el que se prescinde de <i>TMIN</i>					
% variabilidad explicada por modelo					
	Global	Invierno	Primavera	Verano	Otoño
Modelo	33.18	36.85	31.97	31.1	28.13
Ocurrencia	41.38	46.04	35.74	41.54	38.69
Cantidad	19.89	24.33	15.98	16.99	14.92
Valores esperados a partir del modelo, con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	81.2	20.9	20.6	14.6	25.1
% cambio	-1.19	-5.13	-8.65	-2.83	10.3
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	2950.0	646.0	918.0	556.0	835.0
% cambio	1.2	-0.366	1.28	7.31	-1.79
Valores ajustados por el modelo, con los datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Proyección	80.9	21.4	17.4	15.4	26.5
% cambio	-1.54	-2.68	-22.8	3.08	16.6
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Proyección	2910.0	577.0	643.0	608.0	1090.0
% cambio	-0.16	-11.0	-29.0	17.4	27.6
Modelo <i>Down1</i> en el que se prescinde de <i>TDIF</i>					
% variabilidad explicada por modelo					
	Global	Invierno	Primavera	Verano	Otoño
Modelo	25.85	30.2	26.8	22.01	19.26
Ocurrencia	39.49	44.1	34.18	38.19	37.9
Cantidad	11.67	16.61	12.99	5.2	4.43
Valores ajustados por el modelo, con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	81.2	21.3	20.2	14.4	25.3
% cambio	-1.09	-3.28	-10.3	-4.17	11.3
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	3130.0	705.0	943.0	566.0	918.0
% cambio	7.31	8.78	4.07	9.26	7.99
Valores ajustados por el modelo, con los datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Proyección	83.5	21.8	17.9	15.5	28.2
% cambio	1.7	-1.12	-20.4	3.77	23.9
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Proyección	3240.0	737.0	693.0	640.0	1160.0
% cambio	10.9	13.6	-23.5	23.5	37.0

Tabla C.24: Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000.

Modelo <i>Down1</i> en el que se prescinde de <i>TDIF</i> y <i>TMIN</i>					
% variabilidad explicada por modelo					
	Global	Invierno	Primavera	Verano	Otoño
Modelo	22.17	24.86	21.53	21.56	16.74
Ocurrencia	39.02	44.37	33.72	37.17	37.13
Cantidad	6.73	9.49	4.65	5.07	1.49
Valores ajustados por el modelo, con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	81.0	21.0	20.2	14.3	25.3
% cambio	-1.42	-4.72	-10.1	-4.26	11.4
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	3000.0	647.0	903.0	533.0	919.0
% cambio	2.82	-0.199	-0.35	2.92	8.01
Valores ajustados por el modelo, con los datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Proyección	83.5	21.6	18.4	15.6	27.9
% cambio	1.71	-1.93	-18.4	4.17	22.5
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Proyección	3210.0	621.0	828.0	647.0	1110.0
% cambio	9.98	-4.19	-8.64	24.9	31.1
Modelo <i>Down1</i> en el que se prescinde de <i>A500.00</i>					
% variabilidad explicada por modelo					
	Global	Invierno	Primavera	Verano	Otoño
Modelo	44.25	50.72	41.05	39.56	38.59
Ocurrencia	40.68	43.19	33.57	43.98	38.41
Cantidad	34.05	43.68	30.46	24.69	26.11
Valores esperados a partir del modelo, con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	82.2	21.8	20.8	15.0	24.6
% cambio	0.136	-1.11	-7.75	0.028	8.34
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	3110.0	745.0	919.0	640.0	811.0
% cambio	6.7	14.9	1.43	23.6	-4.69
Valores ajustados por el modelo, con los datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primavera	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Proyección	79.1	21.6	15.9	15.6	25.9
% cambio	-3.7	-1.97	-29.4	4.21	13.8
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Proyección	2080.0	498.0	385.0	506.0	691.0
% cambio	-28.7	-23.2	-57.5	-2.31	-18.8

Tabla C.25: Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación.

Mejor modelo de lluvia que prescinde de <i>TMIN</i> , <i>TDIF</i> y <i>A500.00</i>					
% variabilidad explicada por modelo					
	Global	Invierno	Primav.	Verano	Otoño
Modelo	26.54	26.33	32.51	28	18.42
Ocurrencia	39.93	43.84	35.31	40.85	36.55
Cantidad	11.44	10.31	17.76	12.66	2.88
Valores esperados a partir del modelo, con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	82.2	21.2	20.6	14.8	25.5
% cambio	0.0168	-3.87	-8.59	-1.05	12.1
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	2940.0	698.0	920.0	466.0	859.0
% cambio	0.801	7.64	1.46	-10.1	0.992
Valores ajustados por el modelo, con los datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Proyección	79.3	19.0	17.0	17.0	26.2
% cambio	-3.44	-13.6	-24.5	13.4	15.4
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Proyección	2560.0	576.0	628.0	460.0	898.0
% cambio	-12.2	-11.2	-30.7	-11.2	5.54

Tabla C.26: Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación.

Mejor modelo que prescinde de <i>TDIF</i> y <i>TMIN</i>					
% variabilidad explicada por modelo					
	Global	Invierno	Primav.	Verano	Otoño
Modelo	30.41	32.08	33.04	30.2	23.61
Ocurrencia	40.2	44.9	34.23	40.03	37.95
Cantidad	16.83	18.18	21.72	13.56	10.04
Valores esperados a partir del modelo, con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	82.1	21.0	20.5	14.7	25.8
% cambio	-0.0999	-4.78	-9.09	-1.61	13.5
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	2920.0	678.0	921.0	458.0	861.0
% cambio	-0.0389	4.52	1.63	-11.6	1.23
Valores ajustados por el modelo, con los datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Proyección	83.3	20.1	18.0	17.3	27.8
% cambio	1.39	-8.85	-19.9	15.6	22.2
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Proyección	2860.0	590.0	768.0	549.0	949.0
% cambio	-2.13	-8.94	-15.2	6.05	11.6

Tabla C.27: Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación.

Mejor modelo que prescinde de <i>TDIF</i> y <i>QSUP</i>					
% variabilidad explicada por modelo					
	Global	Invierno	Primav.	Verano	Otoño
Modelo	19.64	18.28	17.88	22.2	19.71
Ocurrencia	32.66	36.98	19.92	31.32	36.62
Cantidad	6.68	0	11.22	11	8.38
Valores ajustados por el modelo, con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	83.8	21.2	20.7	15.7	26.2
% cambio	2.04	-3.72	-8.21	4.85	15.1
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	3060.0	716.0	1030.0	451.0	861.0
% cambio	4.66	10.4	13.3	-13.0	1.29
Valores ajustados por el modelo, con los datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Proyección	93.4	21.6	23.3	21.0	27.5
% cambio	13.7	-2.09	3.36	40.2	20.9
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Proyección	3550.0	717.0	1230.0	615.0	987.0
% cambio	21.6	10.5	36.2	18.8	16.0

Tabla C.28: Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación.

Mejor modelo que prescinde de <i>QSUP</i>					
% variabilidad explicada por modelo					
	Global	Invierno	Primav.	Verano	Otoño
Modelo	40.4	44.43	37.44	36.93	37.8
Ocurrencia	37.05	41.03	23.73	38.06	39.78
Cantidad	31	35.76	30.64	27.76	22.92
Valores ajustados por el modelo, con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	84.0	21.6	21.2	15.5	25.6
% cambio	2.29	-1.76	-5.59	3.15	12.6
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	3150.0	852.0	960.0	562.0	777.0
% cambio	7.99	31.4	5.88	8.61	-8.67
Valores ajustados por el modelo, con los datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Proyección	88.2	22.6	21.4	18.4	25.7
% cambio	7.4	2.55	-4.7	23.1	12.9
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Proyección	3920.0	749.0	1100.0	954.0	1120.0
% cambio	34.4	15.5	21.3	84.3	32.1

Tabla C.29: Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación.

Mejor modelo con <i>PSUP</i> , A850.00, Q850.00, T500.00, Q500.00 y T85/50.00					
% variabilidad explicada por modelo					
	Global	Invierno	Primav.	Verano	Otoño
Modelo	19.43	19.9	13.49	19.28	22.66
Ocurrencia	29.03	32.36	17.55	26.53	34.11
Cantidad	9.78	9.86	9.19	10.77	6.15
Valores ajustados por el modelo, con los datos observados					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Modelo datos observ.	84.0	22.1	21.2	15.2	25.5
% cambio	2.33	0.386	-5.62	1.17	11.9
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Modelo datos observ.	2970.0	724.0	950.0	446.0	852.0
% cambio	1.87	11.7	4.79	-13.8	0.206
Valores ajustados por el modelo, con los datos del GCM para 1990-2000					
Frecuencia media de días con precipitación					
	Anual	Invierno	Primav.	Verano	Otoño
Observ.	82.1	22.0	22.5	15.0	22.8
Proyección	86.5	22.4	22.1	17.0	24.9
% cambio	5.33	1.66	-1.71	13.6	9.54
Media cantidad acumulada					
Observ.	2920.0	648.0	906.0	518.0	850.0
Proyección	3040.0	746.0	948.0	483.0	861.0
% cambio	4.11	15.1	4.57	-6.64	1.24

Tabla C.30: Régimen de lluvia observado y ajustado por los modelos a partir de los datos observados y generados por CGCM1 para el periodo 1990-2000. Continuación.

## C.4 Downscaling con el modelo *Down2*

Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-1.808	0.1098	-16.470
$S1$	-0.165	0.1119	-1.475
$C1$	0.3282	0.133	2.467
$S2$	-0.4914	0.09937	-4.945
$C2$	-0.207	0.1164	-1.778
$S3$	0.2373	0.09773	2.428
$C3$	0.3056	0.1001	3.052
$S4$	0.2764	0.09727	2.842
$C4$	-0.1794	0.09483	-1.892
$z.PSUP_t$	-0.01796	0.002392	-7.507
$z.PSUP_t^2$	-3.365e-5	1.130e-5	-2.978
$z.PSUP_{t-1}$	0.009472	0.003752	2.524
$z.A850.00_{t-1}$	-0.00726	0.003371	-2.154
$z.Q850.00_{t+1}$	135.100	75.990	1.778
$z.Q850.00_{t+1}^2$	-9.587e4	2.650e4	-3.618
$z.Q500.00_t$	538.400	141.700	3.798
$z.Q500.00_{t+1}$	615.500	149.200	4.125
$z.T500.00_{t+1}$	-0.01766	0.002746	-6.430
<i>invierno</i> : $z.TMIN_t$	-0.02443	0.007157	-3.414
<i>invierno</i> : $z.TDIF_t$	-0.02716	0.005219	-5.205
<i>invierno</i> : $z.TDIF_t^2$	2.483e-4	1.130e-4	2.198
<i>invierno</i> : $z.QSUP_t$	1063.000	210.400	5.050
<i>primavera</i> : $z.TMIN_t$	0.02668	0.00581	4.591
<i>primavera</i> : $z.A500.00_{t+1}$	-0.004905	0.001755	-2.795
<i>verano</i> : $z.TDIF_t$	-0.02398	0.006042	-3.969
<i>verano</i> : $z.QSUP_t$	447.200	86.990	5.141
<i>verano</i> : $z.A500.00_{t+1}$	-0.01219	0.002992	-4.074
<i>otoño</i> : $z.TDIF_t$	-0.02634	0.004625	-5.694
<i>otoño</i> : $z.QSUP_t$	489.500	89.930	5.443

Tabla C.31: Modelo de ocurrencia de *Down2*.

		Deviance	Gr. lib.
Modelo nulo		2349.76	2152
Modelo ajustado		1475.52	2123
AIC:	1518.83	BIC:	1683
Estad. HL	9.15	p-valor	0.33
% variabilidad explicada por modelo			39.61
Autocorrelación orden 1 en residuos			0.08
% días bien clasificados ( $\leq 0.5$ )		Anual	84.65
Primavera	Verano	Otoño	Invierno
84.74	87.01	84.29	82.4
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	95.08	80.92
	Húmedo	49.26	68.7
%NAS		Anual	47.16
Primavera	Verano	Otoño	Invierno
42.36	41.67	52.78	49.13
% días bien clasificados ( $\leq$ frec. día)		Anual	78.63
Primavera	Verano	Otoño	Invierno
79.96	79.04	76.89	78.6
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	82.01	58.02
	Húmedo	75.56	85.65
%NAS		Anual	46.9
Primavera	Verano	Otoño	Invierno
46.83	40.53	48.35	50.92
Índice relativo de Brier		Anual	39.64
Primavera	Verano	Otoño	Invierno
36.08	38.48	40.66	40.57
Días de precipitación observados y predichos por meses			
Coef. correlación	0.9824	Coef. eficiencia	0.9642
Índice de acuerdo	0.9905	% medio error	0.4446

Tabla C.32: Medidas de bondad de ajuste del submodelo de ocurrencia de *Down2* (1990-1997).

AIC:	510.05	BIC:	638.23
Estad. HL	19.74	p-valor	0.01
% variabilidad explicada por modelo			32.62
Autocorrelación orden 1 en residuos			0.1
% días bien clasificados ( $\leq 0.5$ )		Anual	82.08
Primavera	Verano	Otoño	Invierno
73.83	87.58	81.43	87.57
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	96.17	87.34
	Húmedo	41.67	38.98
%NAS		Anual	34.52
Primavera	Verano	Otoño	Invierno
30	29.63	35	46.34
% días bien clasificados ( $\leq$ frec. día)		Anual	80.46
Primavera	Verano	Otoño	Invierno
75.23	87.58	77.14	81.92
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	86.48	67.09
	Húmedo	66.67	77.97
%NAS		Anual	45.95
Primavera	Verano	Otoño	Invierno
46.46	52.5	38.46	43.86
Índice relativo de Brier		Anual	32.73
Primavera	Verano	Otoño	Invierno
23.01	40.72	30.42	39.47
Días de precipitación observados y predichos por meses			
Coef. correlación	0.7234	Coef. eficiencia	0.2289
Índice de acuerdo	0.7906	% medio error	14.710

Tabla C.33: Medidas de bondad de ajuste del submodelo de ocurrencia de *Down2*, periodo de validación (1998-2000).

Periodo de validación, 1998-2000

Mes	$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	35.95	6	7	-	-
Simul.	15.46	4.72	4.18	0.881	0.553
2	12.4	5	7	-	-
Simul.	25.3	9.3	12.46	0.802	0.397
3	12	3	6.5	-	-
Simul.	15.62	4.58	6.09	0.993	0.538
4	6.4	2	3	-	-
Simul.	7.31	2.45	2.51	0.99	0.441
5	8	4	5	-	-
Simul.	12.37	3.72	5.12	0.911	0.947
6	18.6	4.5	8	-	-
Simul.	20.61	9.85	9.89	0.304	0.225
7	12.8	6	2	-	-
Simul.	18.1	9.02	6.64	0.682	0.899
8	24.1	8	9.25	-	-
Simul.	14.47	7.89	5.47	0.979	0.694
9	9.4	5	3.5	-	-
Simul.	10.65	6.42	3.92	0.926	0.689
10	4	2.5	1.75	-	-
Simul.	7.55	3.82	2.06	0.887	0.194
11	9	6	6.5	-	-
Simul.	12.5	6.25	5.2	0.982	0.829
12	10.65	3.5	4.5	-	-
Simul.	11.45	6.45	3.9	0.906	0.402

Periodo de estimación, 1990-1997

Mes	$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
1	16.8	4	7	-	-
Simul.	16.99	2.6	3.96	0.305	0.07
2	13.4	5	6	-	-
Simul.	22.32	3.7	4.11	0.624	0.226
3	25.05	3.5	9	-	-
Simul.	24.34	3.98	8.57	1	0.988
4	11.45	5.5	6	-	-
Simul.	13.89	3.72	5.68	0.391	0.133
5	25.05	3	3.5	-	-
Simul.	15.42	2.78	3.5	0.964	0.367
6	16	3	6	-	-
Simul.	24.97	3.28	7.38	0.921	0.447
7	19	6	11	-	-
Simul.	18.29	6.15	7.1	0.74	0.663
8	15.8	5	5	-	-
Simul.	16.52	5.42	7.84	0.5	0.571
9	11	5	5	-	-
Simul.	13.87	4.15	4.78	0.805	0.929
10	13	3	6.5	-	-
Simul.	11.83	2.52	3.52	0.535	0.439
11	9.9	2	4	-	-
Simul.	11.33	2.95	4.06	0.729	0.31
12	10.7	3	4.25	-	-
Simul.	13.62	2.8	4.09	0.985	0.577

Tabla C.34: Percentiles de la longitud de racha seca observada y simulada por el modelo  $Down2 - Oc$ , para cada mes, usando los datos observados en Zaragoza, en los periodos de estimación y validación.

Periodo de validación, 1998-2000

	$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
	2	1.5	1	-	-
5.26		1.3	0.99	0.904	1
3		2.5	1	-	-
1.78		1.05	0.35	0.018	0
4.45		1	1	-	-
2.86		1.2	0.8	0.995	0.586
4.6		2	2	-	-
3.74		1.38	1.44	0.712	0.291
6.2		2	1	-	-
2.98		1.2	0.64	0.209	0.04
2		1	0.5	-	-
1.83		1	0.19	1	0.479
2.55		1	0.75	-	-
1.9		1.02	0.42	1	0.601
2		1	0	-	-
1.35		1.03	0.07	0.988	0.243
2		1	1	-	-
1.56		1.23	0.19	0.768	0.188
2		1	1	-	-
2.2		1.3	0.49	1	0.827
1.75		1	0	-	-
2.17		1.32	0.48	1	0.677
3		1	1	-	-
2.84		1.1	0.49	0.981	0.413

Periodo de estimación, 1990-1997

Mes	$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1	5.85	1	2.25	-	-
Simul.	5.57	1.1	1.04	0.656	0.682
Mes 2	3	1	1	-	-
Simul.	3.3	1.15	0.98	1	0.6
Mes 3	3	1	1	-	-
Simul.	3	1	0.64	0.945	0.293
Mes 4	5	2	1	-	-
Simul.	3.72	1.25	1.06	0.901	0.265
Mes 5	5.35	1	2	-	-
Simul.	4.34	1.27	1.24	0.938	0.648
Mes 6	3	1	1	-	-
Simul.	3.09	1.02	0.88	0.95	0.442
Mes 7	3	1	0.5	-	-
Simul.	2.2	1.05	0.66	0.972	0.966
Mes 8	3	1.5	1	-	-
Simul.	3.23	1.02	0.9	0.534	0.129
Mes 9	3	1	1	-	-
Simul.	3.14	1.02	0.9	1	0.83
Mes 10	4	2	2	-	-
Simul.	4.92	1.7	1.55	1	0.952
Mes 11	3	1	1	-	-
Simul.	3.86	1.3	1.26	1	0.657
Mes 12	5	1	1	-	-
Simul.	5.11	1.32	1.41	0.535	0.22

Tabla C.35: Percentiles de la longitud de racha húmeda observada y simulada por el modelo *Down2–Oc*, para cada mes, usando los datos observados en Zaragoza, en los periodos de estimación y validación.

Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	3.030	0.08721	34.750
$S1$	0.04571	0.08924	0.5122
$C1$	-0.0972	0.1115	-0.872
$S2$	-0.2367	0.0804	-2.944
$C2$	-0.4088	0.1012	-4.040
$S3$	0.004259	0.08135	0.05236
$C3$	0.2596	0.0827	3.139
$S4$	0.1617	0.07779	2.079
$C4$	-0.01119	0.07761	-0.1442
$z.A850.00_{t+1}$	-0.00936	0.001482	-6.314
$z.A850.00^2_{t+1}$	-2.218e-5	1.084e-5	-2.047
$z.Q500.00_t$	336.800	100.800	3.343
$z.T85/50.00_{t+1}$	-0.0044	0.002151	-2.045
$z.T85/50.00^2_{t+1}$	-1.433e-4	4.124e-5	-3.475
<i>invierno</i> : $z.TDIF_t$	-0.01558	0.003439	-4.532
<i>primavera</i> : $z.A500.00_t$	0.002759	0.001195	2.309
<i>verano</i> : $z.QSUP_t$	172.900	71.580	2.416
<i>verano</i> : $z.A500.00_{t+1}$	-0.00439	0.001937	-2.267
Parámetro de dispersión: 1.443			

Tabla C.36: Modelo de cantidad de *Down2*.

		Deviance	Gr. lib.	
Modelo nulo		938.16	529	
Modelo ajustado		733.7	511	
AIC:	5408.46	BIC:	5485.34	
% variabilidad explicada por modelo		17.44		
% variabilidad explicada por el modelo por estaciones				
Primavera	Verano	Otoño	Invierno	
13.58	23.3	10.75	22.7	
Autocorrelación orden 1 en residuos		0.01		
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.9343	Coef. eficiencia	0.8284	
Índice de acuerdo	0.9411	% medio error	1.195	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
5.671	14.930	55.200	14.560	9.641
% días clasificados en los intervalos, si el día anterior seco				
6.873	17.180	51.550	15.810	8.591
% días clasificados en los intervalos, si el día anterior llovió				
4.202	12.180	59.660	13.030	10.920
% días ( $q_{0.10}, q_{0.90}$ )	Primavera,	Verano	Otoño	Invierno
	80.990	89.580	84.470	84.770

Tabla C.37: Medidas de bondad de ajuste del submodelo de cantidad de *Down2* (1990-1997).

AIC:	1502.19	BIC:	1556.85	
% variabilidad explicada por modelo			4.93	
% variabilidad explicada por el modelo por estaciones				
Primavera	Verano	Otoño	Invierno	
10.44	0	22.67	0	
Autocorrelación orden 1 en residuos			-0.01	
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.5917	Coef. eficiencia	-0.1958	
Índice de acuerdo	0.7207	% medio error	21.720	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
9.091	19.480	50.650	9.091	11.690
% días clasificados en los intervalos, si el día anterior seco				
8.511	19.150	54.260	8.511	9.574
% días clasificados en los intervalos, si el día anterior llovió				
10.000	20.000	45.000	10.000	15.000
% días	Primavera	Verano	Otoño	Invierno
$(q_{0.10}, q_{0.90})$	77.140	75.860	82.350	84.210

Tabla C.38: Medidas de bondad de ajuste del submodelo de cantidad de *Down2*, periodo de validación (1998-2000).

Periodo de validación, 1998-2000

Mes	90.95	90.50	90.75 - 90.25	KS	Wilcoxon
1	84.75	8.5	39.25	-	-
Simul.	136.17	17.97	42.75	0.319	0.226
2	81	6	25	-	-
Simul.	145.54	16.84	39.67	0.441	0.231
3	93	13.5	40	-	-
Simul.	139.09	17.26	38.75	0.939	0.712
4	132.25	9.5	20.25	-	-
Simul.	125.44	17.29	38.97	0.194	0.311
5	191	14	38	-	-
Simul.	127.48	16.84	38.07	0.929	0.881
6	80.2	32	50.5	-	-
Simul.	137.9	18.76	39.07	0.677	0.453
7	120.55	13.5	38.25	-	-
Simul.	145.7	21.09	47.71	0.617	0.991
8	89.8	9	18	-	-
Simul.	140.4	18.16	37.83	0.18	0.253
9	74.8	18.5	39.75	-	-
Simul.	120.38	18.51	36.13	0.97	0.926
10	86.75	17	49.75	-	-
Simul.	124.24	19.08	41.6	0.652	0.636
11	104.5	7	31.5	-	-
Simul.	106.54	17.35	40.37	0.263	0.239
12	56.4	7	12	-	-
Simul.	124.86	18.67	41.31	0.093	0.07

Periodo de estimación, 1990-1997

Mes	90.95	90.50	90.75 - 90.25	KS	Wilcoxon
1	107.8	15	54.5	-	-
Simul.	128.3	18.43	41.63	0.732	0.893
2	90	21.5	34.75	-	-
Simul.	122.16	16.99	41.54	0.797	0.684
3	64	14	22	-	-
Simul.	133.14	16.61	41.09	0.359	0.501
4	216	26	61	-	-
Simul.	132.69	18.89	40.25	0.266	0.134
5	159.5	24	44.5	-	-
Simul.	129.85	17.41	41.59	0.099	0.059
6	144.8	21	28	-	-
Simul.	125.92	19.11	38.43	0.593	0.581
7	98.65	16	36	-	-
Simul.	131.44	16.2	44.93	0.956	0.954
8	122.5	12	27.5	-	-
Simul.	123.76	17	37.24	0.532	0.645
9	255.5	16	56	-	-
Simul.	122.8	20.73	39.96	0.413	0.714
10	144.6	22	33	-	-
Simul.	127.86	17.75	41	0.242	0.601
11	98.1	11	28.75	-	-
Simul.	137.47	17.08	37.48	0.253	0.286
12	107.25	15.5	26.5	-	-
Simul.	150.48	19.28	42.72	0.126	0.225

Tabla C.39: Percentiles de las cantidades observadas y simuladas por el modelo Down2 - C, usando los datos en los días de lluvia observados en Zaragoza.

		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1	Obs.	18	5	7	–	–
	Sim. obs.	17.2	3	4.6	0.348	0.085
	Sim. CGCM1	14.7	3.3	5.2	0.375	0.103
Mes 2	Obs.	13.5	5	6.5	–	–
	Sim. obs.	27.5	4.1	6	0.766	0.556
	Sim. CGCM1	18.1	4.7	6.5	0.948	0.651
Mes 3	Obs.	21	3	7.5	–	–
	Sim. obs.	22.8	4	8.3	1	0.692
	Sim. CGCM1	21.6	5.8	8.6	0.424	0.133
Mes 4	Obs.	9.4	3	6	–	–
	Sim. obs.	12.8	3	4.6	0.996	0.619
	Sim. CGCM1	13	3.7	5.5	0.853	0.52
Mes 5	Obs.	20.2	3	4	–	–
	Sim. obs.	14.7	2.8	4.2	0.936	0.385
	Sim. CGCM1	14	3.4	5.6	0.996	0.809
Mes 6	Obs.	18.8	4	8	–	–
	Sim. obs.	24.8	3.9	9.4	0.84	0.443
	Sim. CGCM1	27.2	6.3	10	0.038	0.026
Mes 7	Obs.	17.6	6	8.5	–	–
	Sim. obs.	19.5	6.2	7.3	0.838	0.731
	Sim. CGCM1	23.1	5.8	9.6	0.262	0.505
Mes 8	Obs.	23	5	8	–	–
	Sim. obs.	17.6	5.5	7.8	0.45	0.375
	Sim. CGCM1	19.2	5	6.8	0.593	0.358
Mes 9	Obs.	10.4	5	5	–	–
	Sim. obs.	14.1	4.2	5.2	0.993	0.854
	Sim. CGCM1	16.8	4.1	6.3	0.715	0.896
Mes 10	Obs.	11.8	3	4	–	–
	Sim. obs.	11.9	2.7	3.4	0.867	0.732
	Sim. CGCM1	15.6	2.5	4.8	0.926	0.558
Mes 11	Obs.	9.6	2	5	–	–
	Sim. obs.	12	3.1	4.4	0.816	0.37
	Sim. CGCM1	15.7	3.3	5.8	0.297	0.072
Mes 12	Obs.	11.1	3	5	–	–
	Sim. obs.	14.2	3	4.5	0.99	0.53
	Sim. CGCM1	11.7	3.1	4.6	0.847	0.36

Tabla C.40: Percentiles de la longitud de racha seca observada y simulada por el modelo *Down2*, para cada mes, usando los datos observados en Zaragoza y los generados por CGCM1 para el periodo 1990-2000.

		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1	Obs.	5.3	1	1	–	–
	Sim. obs.	5.8	1.1	1.1	0.996	0.724
	Sim. CGCM1	3.7	1	1	0.775	0.408
Mes 2	Obs.	3	2	1.5	–	–
	Sim. obs.	3.2	1.1	0.9	0.324	0.046
	Sim. CGCM1	3.2	1	0.9	0.18	0.013
Mes 3	Obs.	3.5	1	1	–	–
	Sim. obs.	3.1	1	0.7	0.898	0.227
	Sim. CGCM1	2.9	1	0.8	0.965	0.229
Mes 4	Obs.	5	2	1.8	–	–
	Sim. obs.	3.8	1.2	1.2	0.339	0.095
	Sim. CGCM1	4.5	1.2	1.1	0.308	0.071
Mes 5	Obs.	6.4	2	2	–	–
	Sim. obs.	4.2	1.2	1	0.943	0.195
	Sim. CGCM1	4.2	1.2	1.3	0.876	0.198
Mes 6	Obs.	2.4	1	1	–	–
	Sim. obs.	3	1	0.8	0.977	0.492
	Sim. CGCM1	3.4	1	0.9	0.999	0.679
Mes 7	Obs.	3	1	1	–	–
	Sim. obs.	2.2	1	0.6	0.956	0.801
	Sim. CGCM1	3.4	1	1	0.994	0.393
Mes 8	Obs.	3	1	1	–	–
	Sim. obs.	3.1	1	0.8	0.728	0.211
	Sim. CGCM1	3.6	1	0.6	0.405	0.084
Mes 9	Obs.	3	1	1	–	–
	Sim. obs.	3.1	1	0.8	1	0.624
	Sim. CGCM1	3.8	1	1	0.991	0.987
Mes 10	Obs.	4	2	1	–	–
	Sim. obs.	4.8	1.6	1.4	1	0.997
	Sim. CGCM1	5.4	1.2	1.3	0.976	0.583
Mes 11	Obs.	3	1	1	–	–
	Sim. obs.	3.8	1.2	1.3	1	0.502
	Sim. CGCM1	5.7	1.7	1.6	0.341	0.034
Mes 12	Obs.	4.5	1	1	–	–
	Sim. obs.	4.9	1.2	1.4	0.903	0.354
	Sim. CGCM1	3.5	1	1	0.713	0.853

Tabla C.41: Percentiles de la longitud de racha húmeda observada y simulada por el modelo *Down2*, para cada mes, usando los datos observados en Zaragoza y los generados por CGCM1 para el periodo 1990-2000.

		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1	Obs.	155.95	18	47	–	–
	Sim. obs.	116.78	14.09	34.17	0.007	0.002
	Sim. CGCM1	89.38	11.94	27.53	0	0
Mes 2	Obs.	126.2	17	37	–	–
	Sim. obs.	170.82	16.53	44.55	0.113	0.62
	Sim. CGCM1	96.98	11.77	26.37	0.007	0
Mes 3	Obs.	157.8	20	40	–	–
	Sim. obs.	73.51	11.42	22.16	0	0
	Sim. CGCM1	74.54	11.36	24.51	0	0
Mes 4	Obs.	135.4	15	36.75	–	–
	Sim. obs.	206.08	29.82	67.65	0	0
	Sim. CGCM1	169.22	26.18	58.89	0	0
Mes 5	Obs.	125.4	15	30	–	–
	Sim. obs.	160.79	23.45	50.13	0	0
	Sim. CGCM1	135.38	19.78	45.4	0.034	0.046
Mes 6	Obs.	132.7	12	36.5	–	–
	Sim. obs.	103.27	14.06	32.23	0.115	0.688
	Sim. CGCM1	136.39	15.44	35.02	0.08	0.89
Mes 7	Obs.	140.05	13.5	31	–	–
	Sim. obs.	101.21	15.79	37.49	0.185	0.303
	Sim. CGCM1	103.38	12.25	28.14	0.004	0.169
Mes 8	Obs.	121.85	16	35.25	–	–
	Sim. obs.	159.93	20.16	44.57	0.075	0.038
	Sim. CGCM1	126.1	14.7	37.81	0.01	0.559
Mes 9	Obs.	142.2	15	36	–	–
	Sim. obs.	118.51	18.04	37.4	0.031	0.453
	Sim. CGCM1	112.15	15.33	33.98	0.034	0.635
Mes 10	Obs.	157	18	40.75	–	–
	Sim. obs.	138.27	18.83	44.81	0.048	0.616
	Sim. CGCM1	145.36	19.86	41.52	0.069	0.401
Mes 11	Obs.	122.9	14.5	35	–	–
	Sim. obs.	99.21	12.8	31.01	0.012	0.06
	Sim. CGCM1	113.17	12.9	31.97	0.007	0.038
Mes 12	Obs.	134.6	16	34	–	–
	Sim. obs.	121.27	13.32	32.19	0.006	0.011
	Sim. CGCM1	127.56	14.15	35.53	0.012	0.125

Tabla C.42: Percentiles de las cantidades observadas y simuladas por el modelo *Down2*, para cada mes, usando los datos observados y los generados por CGCM1 para 1990-2000.

## **C.5 Downscaling para el periodo 2090-2100**

		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1	Obs.	18	5	7	–	–
	Simul.	11.3	2.6	4	0.051	0.013
Mes 2	Obs.	13.5	5	6.5	–	–
	Simul.	29	4.2	7.7	0.815	0.554
Mes 3	Obs.	21	3	7.5	–	–
	Simul.	27.8	6.9	12.6	0.155	0.012
Mes 4	Obs.	9.4	3	6	–	–
	Simul.	21.2	4.3	7.8	0.045	0.048
Mes 5	Obs.	20.2	3	4	–	–
	Simul.	29.9	5.3	7.7	0.033	0.009
Mes 6	Obs.	18.8	4	8	–	–
	Simul.	40.4	7.9	17.2	0.021	0.007
Mes 7	Obs.	17.6	6	8.5	–	–
	Simul.	21.7	5.4	8	0.198	0.297
Mes 8	Obs.	23	5	8	–	–
	Simul.	12.7	4.1	5.6	0.136	0.022
Mes 9	Obs.	10.4	5	5	–	–
	Simul.	8.2	2.4	2.8	0.001	0
Mes 10	Obs.	11.8	3	4	–	–
	Simul.	11.2	2.2	3.5	0.785	0.242
Mes 11	Obs.	9.6	2	5	–	–
	Simul.	12	2.6	4	0.996	0.743
Mes 12	Obs.	11.1	3	5	–	–
	Simul.	10.8	2.6	3.7	0.986	0.839

Tabla C.43: Percentiles de las longitudes de rachas secas observadas y simuladas por el modelo *Down2*, para cada mes, usando los datos generados por CGCM1 para el periodo 2090-2100.

		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1	Obs.	5.3	1	1	–	–
	Simul.	4.3	1	1.1	0.998	0.883
Mes 2	Obs.	3	2	1.5	–	–
	Simul.	3.1	1	0.9	0.246	0.016
Mes 3	Obs.	3.5	1	1	–	–
	Simul.	2.1	1	0.1	0.056	0
Mes 4	Obs.	5	2	1.8	–	–
	Simul.	3.3	1	1	0.027	0.001
Mes 5	Obs.	6.4	2	2	–	–
	Simul.	3.8	1	0.8	0.052	0.003
Mes 6	Obs.	2.4	1	1	–	–
	Simul.	3.7	1.1	0.6	0.967	0.588
Mes 7	Obs.	3	1	1	–	–
	Simul.	3.6	1	0.4	1	0.738
Mes 8	Obs.	3	1	1	–	–
	Simul.	4.2	1	1.1	0.999	0.916
Mes 9	Obs.	3	1	1	–	–
	Simul.	5.4	1.6	1.6	0.148	0.036
Mes 10	Obs.	4	2	1	–	–
	Simul.	5.1	1.6	1.7	0.999	0.81
Mes 11	Obs.	3	1	1	–	–
	Simul.	3.8	1.2	1.1	1	0.584
Mes 12	Obs.	4.5	1	1	–	–
	Simul.	3.4	1.2	1	0.55	0.388

Tabla C.44: Percentiles de las longitudes de rachas húmedas observadas y simuladas por el modelo *Down2*, para cada mes, usando los datos generados por CGCM1 para el periodo 2090-2100.

		$q_{0.95}$	$q_{0.50}$	$q_{0.75} - q_{0.25}$	KS	Wilcoxon
Mes 1	Obs.	155.95	18	47	–	–
	Simul.	121.92	12.28	33.37	0.001	0
Mes 2	Obs.	126.2	17	37	–	–
	Simul.	97.09	10.72	28.14	0	0
Mes 3	Obs.	157.8	20	40	–	–
	Simul.	126.97	20.99	38.52	0.172	0.335
Mes 4	Obs.	135.4	15	36.75	–	–
	Simul.	253.03	37.03	81.78	0	0
Mes 5	Obs.	125.4	15	30	–	–
	Simul.	191.1	25.6	57.42	0	0
Mes 6	Obs.	132.7	12	36.5	–	–
	Simul.	139.91	13.93	34.68	0.034	0.49
Mes 7	Obs.	140.05	13.5	31	–	–
	Simul.	140.67	14.76	39.98	0.036	0.464
Mes 8	Obs.	121.85	16	35.25	–	–
	Simul.	221.52	27.96	61.06	0	0
Mes 9	Obs.	142.2	15	36	–	–
	Simul.	119.52	14.58	36.03	0.009	0.391
Mes 10	Obs.	157	18	40.75	–	–
	Simul.	137.61	15.01	36.51	0.036	0.235
Mes 11	Obs.	122.9	14.5	35	–	–
	Simul.	103.83	12.99	31.3	0.005	0.03
Mes 12	Obs.	134.6	16	34	–	–
	Simul.	115.28	12.89	30.82	0.003	0.004

Tabla C.45: Percentiles de las cantidades observadas y simuladas por el modelo *Down2*, para cada mes, usando los datos generados por CGCM1 para el periodo 2090-2100.

Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	-1.562	0.09118	-17.130
$S1$	-0.2319	0.08991	-2.580
$C1$	0.2078	0.08832	2.353
$S2$	-0.4542	0.08589	-5.289
$C2$	0.07659	0.08909	0.8597
$S3$	0.1174	0.08637	1.359
$C3$	0.1461	0.08725	1.674
$S4$	0.208	0.08717	2.386
$C4$	-0.1735	0.08652	-2.005
$z.PSUP_t$	-0.03167	0.003247	-9.751
$z.TDIF_t$	-0.03021	0.002426	-12.450
$z.A850.00_t$	0.02483	0.003163	7.849
$z.T500.00_{t+1}$	-0.00732	0.003208	-2.282
$z.A500.00_{t+1}$	-0.003765	0.001761	-2.138
$z.A500.00^2_{t+1}$	-2.318e-5	5.305e-6	-4.369
$z.T85/50.00_t$	-6.814e-5	0.002372	-0.02873
$z.T85/50.00^2_t$	-1.272e-4	5.114e-5	-2.488

Tabla C.46: Modelo de ocurrencia que no usa información de humedad.

Término	Coefficiente	Error std.	Estadístico $t$
$\beta_0$	2.772	0.07331	37.820
$S1$	0.05484	0.06582	0.8331
$C1$	-0.1059	0.06861	-1.544
$S2$	-0.1661	0.06207	-2.677
$C2$	0.08935	0.06474	1.380
$S3$	0.1469	0.06157	2.385
$C3$	0.0718	0.06502	1.104
$z.PSUP_t$	-0.01503	0.003374	-4.456
$z.TMIN_t$	-0.01287	0.002378	-5.413
$z.TDIF_t$	-0.0154	0.002246	-6.857
$z.TDIF_t^2$	8.771e-5	3.443e-5	2.547
$z.A850.00_t$	0.01054	0.003946	2.670
$z.A850.00_{t+1}$	-0.005894	0.002832	-2.081
$z.T500.00_{t+1}$	-0.009024	0.002974	-3.034
$z.A500.00_t$	0.003806	0.001376	2.767
$z.A500.00_{t+1}$	8.230e-4	0.002284	0.3603
$z.A500.00^2_{t+1}$	-2.488e-5	3.594e-6	-6.922

Tabla C.47: Modelo de cantidad que no usa información de humedad.

		Deviance	Gr. lib.
Modelo nulo		2460.9	2267
Modelo ajustado		1729.99	2250
AIC:	1763.99	BIC:	1861.34
Estad. HL	8.29	p-valor	0.41
% variabilidad explicada por modelo			32
Autocorrelación orden 1 en residuos			0.12
% días bien clasificados (0.5)		Anual	82.8
Primavera	Verano	Otoño	Invierno
84.64	84.97	79.62	81.95
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	95.34	83.51
	Húmedo	41.58	55.27
% aciertos, sin secos previstos secos		Anual	39.25
Primav.	Verano	Otoño	Invierno
40.14	17.31	42.16	47.59
% días bien clasificados (frec. día)		Anual	75.21
Primav.	Verano	Otoño	Invierno
79.23	73.78	73.58	74.22
Día $t - 1$		Seco	Húmedo
Día $t$	Seco	78.08	53.76
	Húmedo	72.85	85.65
%NAS		Anual	42.48
Primav.	Verano	Otoño	Invierno
43.87	34.21	45.94	44.88
Índices de Brier		Anual	32.03
Primav.	Verano	Otoño	Invierno
35.16	23.37	32.27	32.68
Días de precipitación observados y predichos por meses			
Coef. correlación	0.9572	Coef. eficiencia	0.9159
Índice de acuerdo	0.9771	% medio error	-0.6485

Tabla C.48: Medidas de bondad de ajuste para el modelo de ocurrencia que no usa información de humedad (1990-1997).

		Deviance	Gr. lib.	
Modelo nulo		1273.27	688	
Modelo ajustado		917.24	671	
AIC:	7256.73	BIC:	7333.81	
% variabilidad explicada por modelo		29.58		
% variabilidad explicada por el modelo por estaciones				
Primav.	Verano	Otoño	Invierno	
35.38	17.44	28.04	28.63	
Autocorrelación orden 1 en residuos		0		
Cantidad media de precipitación observada y ajustada por meses				
Coef. correlación	0.8664	Coef. eficiencia	0.7356	
Índice de acuerdo	0.9283	% medio error	-0.8188	
% días con cantidad registrada en los intervalos definidos por los percentiles de su distribución ajustada				
< $q_{0.10}$	$[q_{0.10}, q_{0.25})$	$[q_{0.25}, q_{0.75}]$	$(q_{0.75}, q_{0.90}]$	> $q_{0.90}$
7.267	15.700	51.740	14.970	10.320
% días clasificados en los intervalos, si el día anterior seco				
8.718	17.440	50.000	14.870	8.974
% días clasificados en los intervalos, si el día anterior llovió				
5.369	13.420	54.030	15.100	12.080
% días				
$q_{10}, q_{90}$	Primav.	Verano	Otoño	Invierno
	81.870	83.460	84.920	79.890

Tabla C.49: Medidas de bondad de ajuste para el modelo de cantidad que no usa información de humedad (1990-1997).