



Universidad de Buenos Aires
Facultad de Ciencias Exactas y Naturales

Biblioteca Digital FCEN-UBA

Variabilidad intraestacional de alta y baja frecuencia de la temperatura máxima y mínima diaria en Sudamérica. Estudio de la predictabilidad mediante la entropía condicional

Naumann, Gustavo

2009

Tesis Doctoral

Facultad de Ciencias Exactas y Naturales
Universidad de Buenos Aires

www.digital.bl.fcen.uba.ar

Contacto: digital@bl.fcen.uba.ar

Este documento forma parte de la colección de tesis doctorales de la Biblioteca Central Dr. Luis Federico Leloir. Su utilización debe ser acompañada por la cita bibliográfica con reconocimiento de la fuente.

This document is part of the doctoral theses collection of the Central Library Dr. Luis Federico Leloir. It should be used accompanied by the corresponding citation acknowledging the source.

Fuente / source:

Biblioteca Digital de la Facultad de Ciencias Exactas y Naturales - Universidad de Buenos Aires



Universidad de Buenos Aires
Facultad de Ciencias Exactas y Naturales
Departamento de Ciencias de la Atmósfera y los Océanos

**Variabilidad intraestacional de alta y baja frecuencia de la
temperatura máxima y mínima diaria en Sudamérica.
Estudio de la predictabilidad mediante la entropía condicional.**

Gustavo Naumann

**Tesis presentada para optar por el título de Doctor de la Universidad de Buenos Aires
en el área Ciencias de la Atmósfera y los Océanos**

**Director: Dr. Walter Mario Vargas
Consejero de Estudios: Dr. Walter Mario Vargas**

**Departamento de Ciencias de la Atmósfera y los Océanos
Buenos Aires, 2009**

A EMMA

Agradecimientos

A Mercedes quien me acompaña incondicionalmente.

A Estela y Guillermo, mis padres, quienes me brindaron absolutamente todo para que sea feliz.

A Karin y Sebastián, que siempre están preocupados por mis cosas, y en especial por ser los padres de Nahuel, Santi y Sofía.

A Walter Vargas quien no solo me guió en la confección de este trabajo, que, estuvo en los buenos y malos momentos, siempre con el mejor consejo.

A Ezequiel, Ana Laura, Maria Paula, Nati, Eugenia, Evan, Charlie, Maxi y Hernán por los momentos compartidos.

Al Servicio Meteorológico Nacional, al Laboratorio Climatológico Sudamericano, al Departamento de Ciencias de la Atmósfera y los Océanos y CLARIS por suministrar la información necesaria para la elaboración de este trabajo.

A los proyectos UBA X-234, UBA X-228 y CONICET PIP 5139 por sus aportes en el desarrollo de este trabajo.

INDICE

RESUMEN.....	8
ABSTRACT.....	10
INTRODUCCION.....	12
CAPITULO 1	
(DATOS Y METODOS).....	17
1.1 Criterio de selección de las estaciones de referencia.....	17
1.2 Climatología General.....	19
1.3 Análisis de Consistencia.....	26
1.4 Análisis de inhomogeneidades en las series temporales.....	28
1.4.1 Caso Corrientes.....	31
1.4.2 Caso Río Gallegos.....	37
1.4.3 Efecto de calentamiento urbano.....	38
1.5 Métodos.....	41
1.5.1 Métodos de análisis espectral.....	41
1.5.2 Análisis Armónico.....	42
1.5.3 Método de Blackman –Tukey.....	43
1.5.4 Análisis espectral wavelet.....	44
1.5.5 Métodos de Clasificación.....	47
1.5.6 Análisis de Cluster.....	48
1.5.7 P.A.M. (Partitioning Around Medoids).....	48
1.5.8 K-MEANS.....	50
1.5.9 Identificación del número de clusters.....	51
1.5.10 Análisis de Componentes principales.....	52

CAPITULO 2

(ESTIMACION Y FILTROS DE LA ONDA ANUAL).....56

2.1 Variación estacional en escala diaria de la temperatura y precipitación.....56

2.2 Modelos de descomposición de series temporales.....57

2.2.1 Modelo de descomposición aditivo.....58

2.2.2 Modelo de descomposición multiplicativo.....59

2.3 Métodos basados en filtros.....63

2.3.1 Estimación de la onda anual mediante los promedios diarios.....63

2.3.2 Estimación de la onda anual basada en análisis armónico.....70

2.4 Estabilidad y robustez de la de Función de autocorrelación y estimaciones espectrales.....77

CAPITULO 3

(ANALISIS DE LA PERSISTENCIA SOBRE LA TEMPERATURA MAXIMA Y MINIMA DIARIA).....88

3.1 Estimación de la función de autocorrelación.....89

3.2 Evolución anual de la persistencia en las series de Temperatura máxima y mínima.....91

3.3 Evolución anual de las memorias lejanas en las series de Temperatura máxima y mínima.....97

3.4 Distribución espacial de la persistencia y memoria lejana del sistema térmico...103

3.5 Variabilidad de baja frecuencia de la persistencia.....113

CAPITULO 4

(PREDICTABILIDAD Y TEORIA DE LA INFORMACION).....121

4.1 Definición de Entropía.....123

4.1.1 Entropía de una secuencia de estados.....125

4.1.2 Entropía local, condicional y dinámica.....126

4.1.3 Entropía Conjunta e información Mutua.....	128
4.2 Análisis de Cluster.....	130
4.2.1 Descripción de la clasificación sobre las series de Temperatura.....	131
4.2.2 Asociación de la clasificación con tipos de circulación.....	135
4.3 Variaciones seculares de la clasificación.....	138
4.4 Estimación de las distribuciones asociadas con las probabilidades de transición.....	142
4.5. Variaciones espaciales de las incertezas.....	143
4.6 Variaciones temporales de la entropía y persistencia.....	145

CAPITULO 5

(PRINCIPALES MODOS DE OSCILACION DE LA TEMPERATURA EN LA ESCALA INTRAESTACIONAL).....	149
---	-----

5.1 Estimación espectral wavelet sobre las series de referencia.....	155
5.2 Variación temporal de estimación espectral wavelet a escala intraestacional.....	161
5.3 Principales modos de oscilación en la escala intraestacional.....	164
5.3.1 Clasificación mediante componentes principales.....	165
5.3.2 Clasificación mediante análisis de cluster.....	168
5.4 Relación entre la variabilidad intraestacional de la temperatura y la oscilación de Madden-Julian.....	180
5.4.1 Descripción sobre la representación de la MJO.....	182
5.4.2 Información mutua entre la temperatura y la oscilación de Madden-Julian...	190
5.4.3 Diagnóstico de la temperatura basada en análisis conjunto local.....	191

CONCLUSIONES.....	196
-------------------	-----

REFERENCIAS.....	203
------------------	-----

ANEXO I.....	220
--------------	-----

RESUMEN

Los pronósticos del tiempo y climáticos mejoran con el aumento de la habilidad de los modelos tanto dinámicos como probabilísticos en identificar situaciones de alto y bajo riesgo. Por esta razón el conocimiento de los procesos que intervienen en la identificación de situaciones con alto riesgo conlleva a una valoración en la información meteorológica por parte del usuario.

Es por esto que la comprensión del funcionamiento del clima y su variabilidad requieren de diagnósticos específicos sobre la precipitación, las temperaturas y la circulación asociada a la misma. Esto adquiere más importancia a medida que la aplicación a diversos sistemas se hace necesaria. Por esto, este trabajo de Tesis tiene como objetivo general contribuir al conocimiento de la estructura de la temperatura máxima y mínima a escala diaria con las series de registros más largos en Sudamérica, que abarcan el período instrumental. Este conocimiento está dirigido a elaborar una climatología de valores diarios que permiten diagnosticar de forma objetiva y a través de síntesis matemática los procesos más importantes en las series de temperatura máxima y mínima diaria.

Por lo tanto, el objetivo principal de este trabajo es obtener un análisis de la variabilidad climática especialmente dentro de la escala intraestacional en series de temperaturas extremas diarias en Sudamérica, para elaborar un diagnóstico y pronóstico objetivo con inferencia directa sobre el impacto.

Palabras claves: Temperatura máxima y mínima diaria, series de referencia, Sudeste de Sudamérica, variabilidad intraestacional, teoría de la información, predictabilidad.

ABSTRACT

Weather and climate forecasts improved with the increased ability of both dynamic and probabilistic models to identify situations of high and low risk. For this reason the knowledge of the processes involved in identifying high risk situations leads to a valuation of meteorological information by the user.

For this reason the understanding of climate variability requires specific diagnostics on precipitation, temperatures and circulation associated with it. This becomes more important as the application to various systems is necessary. Therefore, this thesis work aims to contribute to general knowledge of the structure of the maximum and minimum daily temperature with the longest record series in South America, covering the instrumental period. This knowledge is intended to develop a climatology of daily values that can diagnose objectively and through mathematical synthesis of the most important processes in the series of daily maximum and minimum temperature.

The main objective of this work is to obtain an analysis of climate variability, especially within the intraseasonal scale on series of daily extreme temperatures in South America, to develop an objective diagnosis and prognosis with direct inference on the impact.

Key words: Maximum and Minimum daily Temperature, Reference Series, Southeastern of South America, Intraseasonal Variability, Information Theory, Predictability.

INTRODUCCION

Cuando se toma una decisión basada en información meteorológica, se debe pesar el costo de tomar una medida de protección contra el riesgo de pérdida en el caso que no se tomaran medidas de protección. La proporción entre costo/pérdidas es un importante indicador de la sensibilidad de la información meteorológica. Si las pérdidas esperadas son mayores que el costo de la protección, el usuario decidirá seguramente invertir en la protección. Por otro lado, si el costo de la protección es muy alto es posible que el usuario prefiera no considerarla. Este concepto explica por que algunos usuarios se interesan en los pronósticos del tiempo/climáticos y por que otros no.

Los pronósticos del tiempo y climáticos mejoran con el aumento de la habilidad de los modelos tanto dinámicos como probabilísticos en identificar situaciones de alto y bajo riesgo. Por esta razón el conocimiento de los procesos que intervienen en la identificación de situaciones con alto riesgo conlleva a una valoración en la información meteorológica por parte del usuario.

Es por esto que la comprensión del funcionamiento del clima y su variabilidad requieren de diagnósticos específicos sobre la precipitación, las temperaturas y la circulación asociada a la misma. Esto adquiere más importancia a medida que la aplicación a diversos sistemas se hace necesaria. Se requiere entonces, agregar análisis en escalas diarias ajustando modelos que permitan diagnosticar variabilidades en diversas escalas temporales y aplicaciones con modelos estadísticos.

En especial la variabilidad de baja frecuencia dentro del sistema climático es uno de los principales fenómenos que pueden alterar el funcionamiento de la biosfera y el desarrollo de los seres vivos en ella. Dentro de este sistema, las actividades humanas tanto productivas como culturales interactúan con estas variaciones y por consiguiente un diagnóstico eficaz de éstas es de interés estratégico para enfrentar posibles escenarios climáticos futuros.

Numerosos estudios se han realizado en todo el mundo describiendo las oscilaciones presentes en el sistema climático, destacando Sneyers (1992, 1995), quien presenta en sus trabajos detallados análisis objetivos para la determinación de posibles singularidades tales como saltos climáticos, cambios climáticos, persistencia extrema.

Otros estudios de casos particulares en la región pueden encontrarse en Scian (1970), quien estudió la situación sinóptica asociada con las temperaturas extremadamente bajas, que produjeron excepcionales heladas en amplias zonas de la Argentina durante la primera

quincena de junio en 1967. Rusticucci y Vargas (1995) caracterizaron la circulación de superficie en situaciones de temperatura extremas, olas de calor/frío, desde el punto de vista climático sinóptico, y en casos particulares, Cerne y Rusticucci (1997) analizaron la circulación asociada con una ola de frío extrema que arribó hasta el sur de Brasil y Campetella y Rusticucci (1998) estudiaron con detalle una ola de calor extrema ocurrida en marzo de 1980 en Buenos Aires. Vera y Vigliarolo (2000) realizaron un diagnóstico de la estructura y procesos dinámicos de las olas de frío sobre la región en seis inviernos. Estudios climáticos sobre la ocurrencia de irrupciones extremas de masas de aire cálidas o frías en cualquier época del año, y su variabilidad interanual, se pueden ver en Rusticucci y Vargas (1993, 2001), Vargas y Alessandro (1983) y se muestra su relación con las fases del ENSO en Rusticucci y Vargas (2002). Un estudio climatológico de las temperaturas extremas en Argentina analizando la relación entre la temperatura media estacional y la ocurrencia de días extremos se puede encontrar en Rusticucci y Barrucand (2001) y el estudio de su variabilidad temporal y regional en Barrucand y Rusticucci (2001). Müller et al. (2000, 2003) analizaron la circulación asociada a días con heladas en relación a la fase del ENSO. Rusticucci y Barrucand (2004) analizaron las tendencias de los valores medios, desvíos y extremos (Percentiles 5 y 95) de la temperatura máxima y mínima en Argentina en el período 1959-1998, encontrando que la temperatura mínima de verano presenta las mayores tendencias positivas regionales. Además los autores muestran que el incremento en la temperatura media de verano está fuertemente relacionado con el incremento de la ocurrencia de eventos extremos cálidos.

Dentro de este marco y más enfocado en las variabilidades de largo período o baja frecuencia, Hoffmann (1990), estudió las variaciones decádicas de la temperatura media anual durante el último siglo en Argentina y la región Antártica adyacente, encontrando que no hay variaciones significativas de la temperatura al norte de 45°S, mientras que al sur de esta latitud el autor muestra un calentamiento.

Hoffmann, et al (1997) analizaron la variabilidad de las temperaturas medias decádicas extremas, encontrando un aumento significativo en las temperaturas máximas y mínimas en estaciones ubicadas al sur de 50°S, mientras que para las estaciones ubicadas al norte de 42°S, las temperaturas medias extremas varían en dirección opuesta: la temperatura máxima media presenta tendencia negativa, mientras que la temperatura mínima presenta tendencia

positiva, siendo este patrón consistente con la variación de precipitación y presión de vapor. Vargas, et al (2006) analizaron las tendencias durante el período instrumental a partir de información diaria de temperaturas extremas encontrando que en las estaciones analizadas un incremento en el promedio anual de la temperatura mínima, aunque solo en Corrientes este aumento no es significativo. En cuanto a la temperatura máxima, el comportamiento es uniforme en la región central de Argentina, donde se observan disminuciones en la totalidad del período. Finalmente concuerdan los resultados al indicar que además de los factores de origen antropogénico, las variaciones en las tendencias sobre la temperatura máxima y mínima deberían confirmar la variabilidad en la nubosidad y el contenido de humedad.

En el caso de la variabilidad intraestacional, Leith (1973, 1978), Madden (1976), Brinkmann (1983), Vargas y Ruiz (1993), Trenberth (1984 a, b), Vargas et al (2002), Cerne (2008) y Gonzalez et al (2008) han analizado el comportamiento local y espacial modeladas como procesos estocásticos del tipo señal/ruido. En el mismo sentido Minetti y Vargas (1997) analizaron en varios record de temperatura máxima y mínima diaria en la región de estudio, encontrando principalmente la existencia de una importante interacción entre la onda estacional y las perturbaciones, siendo éstas interacciones de carácter no lineal. Por otro lado se pueden sugerir el ajuste de modelos multivariados como cadenas de Markov de orden infinito y procesos estocásticos (Sneyers, 1990), aunque todavía se desconoce si la cantidad de información disponible es suficiente para éste propósito.

La principal dificultad que presenta el sistema climático es el carácter transitivo de su evolución. En la escala diaria, la evolución del tiempo está caracterizada por abruptos cambios definidos por diversos patrones de circulación. Por consiguiente se puede caracterizar las fluctuaciones del clima en una región por las transiciones entre éstos tipos de circulación. En particular si se analiza la persistencia extendida (Lozowski et al, 1989), particularmente en escala interestacional, se observa un comportamiento de oscilaciones no periódicas, que contienen la noción de compensación climática (eventos de irrupciones cálidas pueden eventualmente ser seguidos por irrupciones de aire frío).

Este trabajo de Tesis tiene como objetivo general contribuir al conocimiento de la estructura de la temperatura máxima y mínima a escala diaria con las series de registros más largas en Sudamérica, que abarcan el período instrumental. Este conocimiento está

dirigido a elaborar una climatología de valores diarios que permitan diagnosticar de forma objetiva y a través de síntesis matemática los procesos más importantes en las series de temperatura máxima y mínima diaria.

Para cumplir este objetivo se toma la experiencia surgida del análisis de las oscilaciones en distinta escala temporal y espacial, como las de aquellas relacionadas con la variabilidad en escala sinóptica, escala intraestacional (Madden-Julian) hasta la variabilidad interdecadal.

Los objetivos anteriores tienen la propiedad de posibilitar el ajuste de modelos estadísticos o estocásticos de las series o muestras estudiadas para problemas de aplicación como son el diagnóstico y pronóstico objetivo. Se detallan los objetivos resultantes de la discusión anterior:

Objetivo Principal

Análisis de la variabilidad climáticas especialmente dentro de la escala intraestacional en series de temperaturas extremas diarias en el sur de Sudamérica, para elaborar un diagnóstico y pronóstico objetivo con inferencia directa sobre el impacto.

Objetivos Particulares

- Estudiar la presencia de los fenómenos aludidos en el objetivo general en series centenarias de Temperatura máxima, Temperatura mínima en el sudeste de Sudamérica.
- Definir las formas de las componentes y/o oscilaciones más importantes en series de temperatura máxima y mínima en escala intraestacional e interanual y sus impactos.
- Inferir los sistemas sinópticos o las características de circulación que fuesen los mayores responsables de la presencia de bajas frecuencias.
- Estimar del grado de predictibilidad del sistema compuesto por las series de temperatura mediante técnica de teoría de la información.

CAPITULO 1

DATOS Y METODOS

1.1 Criterio de selección de las estaciones de referencia.

Se considera como estación o serie de referencia a aquella que dispone de una mayor longitud de registros (en lo posible debe abarcar el período instrumental), su calidad de medición es reconocida y además éstas deben representar a regiones climáticas distintas o particularizadas. Es necesario efectuar el diagnóstico de oscilaciones transientes sobre series de referencia ya que la estabilidad de los resultados esta condicionada a la mayor disponibilidad de información.

Así, al adoptar el criterio de selección de las estaciones de referencia se tomó en cuenta la longitud de los registros, y además se buscó que la distribución geográfica de las estaciones fuese representativa, tratando de describir en la medida de lo posible, las regiones climáticas del Sudeste de Sudamérica, cubriendo una amplia sección latitudinal (la transecta comprende desde los 23° hasta los 55° Sur).

País	Estación	Longitud	Latitud	Inicio	Fin
Argentina	Santa Rosa	-64.26	-36.54	1937	2007
	Río Gallegos	-69.45	-51.99	1896	2007
	Pergamino	-60.53	-33.90	1931	2007
	Corrientes	-58.74	-27.43	1894	2007
	Pilar	-63.85	-31.64	1931	2007
	S. M. Tucumán	-65.20	-26.80	1891	2007
	O.C. Buenos Aires	-58.42	-34.57	1906	2007
Brasil	Campinas	-47.12	-23.00	1890	2003

Tabla 1.1 Descripción, ubicación geográfica y período de observaciones para las ocho estaciones de referencia analizadas.

Luego de aplicar este criterio y en especial condicionado a la disponibilidad de la información se seleccionaron ocho estaciones en Argentina y Brasil (ver Figura 1.1 y Tabla

1.1), de las cuales cinco de ellas poseen registros diarios desde fines del siglo diecinueve y la primera década del siglo veinte.

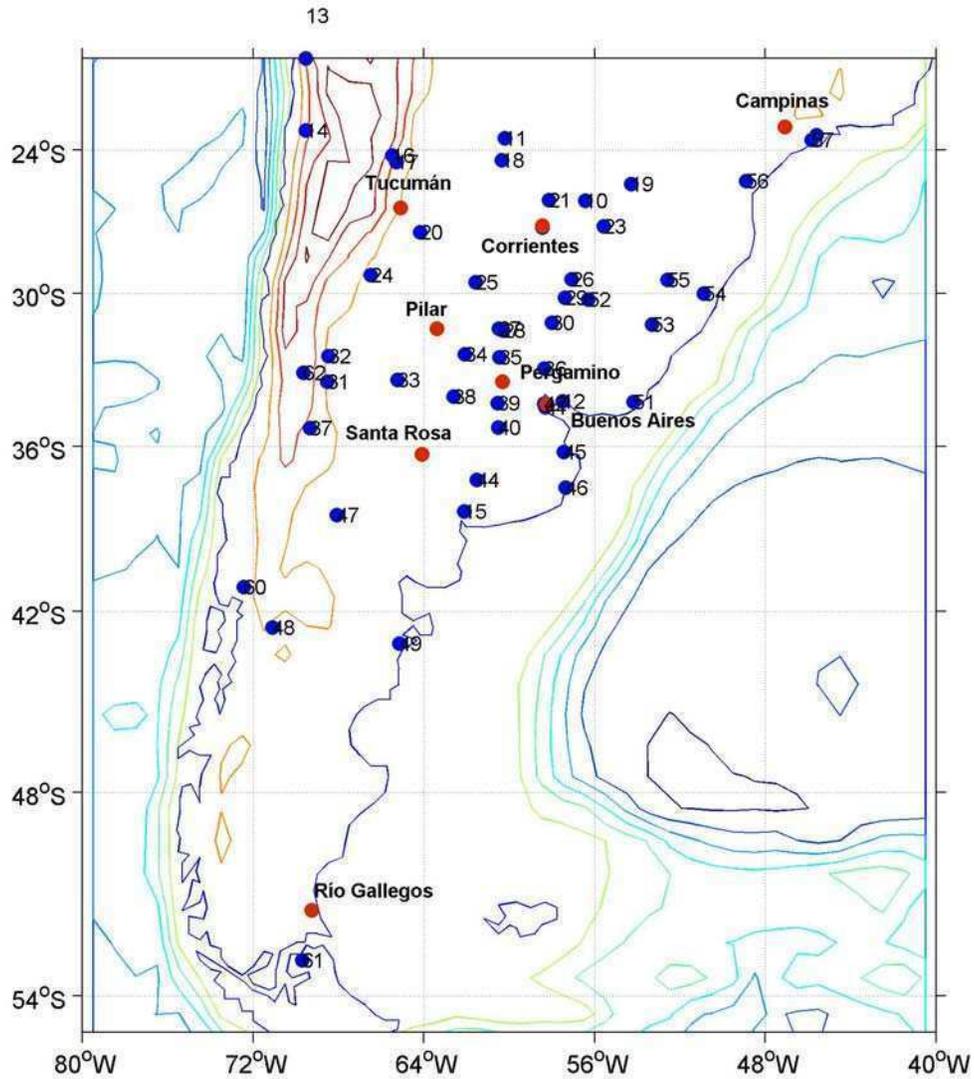


Figura 1.1 Ubicación geográfica de las ocho estaciones de referencia (rojo) y las estaciones de la base de datos regional (azul) de Temperatura máxima y mínima diaria. Las isolíneas representan la topografía en la región.

1.2 Climatología General.

Dada la diversidad de zonas climáticas representadas por las estaciones de referencia se muestra a continuación una breve síntesis sobre su comportamiento a escala anual. En este análisis se diferenciaron tres regiones particulares según su ubicación latitudinal.

La región Norte (Campinas, S. M. De Tucumán y Corrientes), caracterizada por un clima subtropical tanto marítimo como continental; la región Central (Pilar, Buenos Aires, Pergamino y Santa Rosa) de clima Templado y la región Sur (Río Gallegos) regida por la persistente circulación de los oestes.

A continuación se detalla la evolución anual de los valores medios diarios de la temperatura máxima y mínima (T_x y T_n respectivamente) y sus correspondientes desvíos estándar (σ_x y σ_n) en el período completo de mediciones de cada estación.

Región Norte. (Campinas [23.0°S; 47.12°W], S.M. de Tucumán [26.8° S; 65.2°W]), Corrientes [27.4°S; 58.7°W])

Las tres estaciones presentan un régimen térmico similar en cuanto a la ocurrencia de los valores extremos (figura 1.2), es decir los máximos valores de temperatura (tanto T_x como T_n) se observan en el verano, mientras que los mínimos se registran en la época invernal. La principal diferencia entre estas localidades se observa en el rango anual. Tanto en S. M de Tucumán como en Corrientes se observa una amplitud media anual de 14° C en la temperatura máxima y en la mínima, estando éstas caracterizadas por un clima subtropical continental. Aquí los valores de T_x varían entre 33° C y 18° C para las dos estaciones, mientras que T_n toma valores medios aproximados a 20° C en verano y en la época invernal alcanza valores medios de 10° C en Corrientes y de 5° C en S. M. de Tucumán.

En Campinas el régimen térmico está caracterizado por la cercanía de esta localidad al Océano Atlántico. Esto se refleja en el rango térmico anual, siendo la amplitud para T_x de 6° C, mientras que para T_n es de 8° C, casi la mitad que en las otras dos estaciones de la región. La T_x oscila de los 29° C en verano a 23° C en invierno, mientras que T_n varía entre 19° C y 10° C.

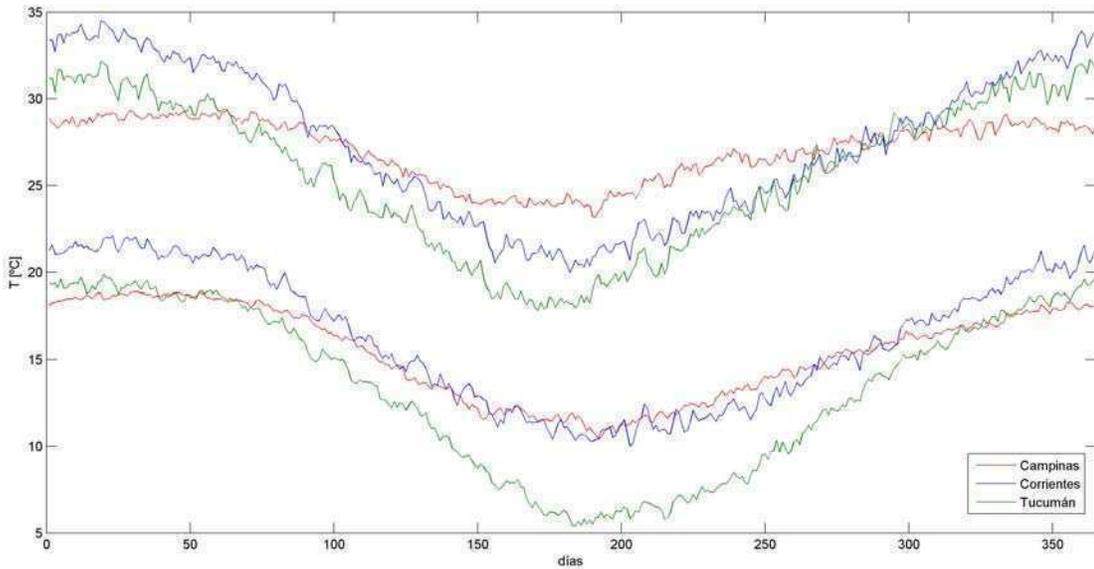


Figura 1.2. Marchas anuales de T_x y T_n para Campinas, Corrientes y S.M. de Tucumán para los respectivos períodos completos de medición.

En cuanto a la variabilidad de las temperaturas extremas, en la figura 1.3 se muestran las marchas anuales de los desvíos estándar en esta región. Es una característica general la presencia de un máximo en los valores de σ_x en primavera, aunque en Corrientes la máxima variabilidad de T_x se observa en los meses invernales. En cuanto a la temperatura mínima, la máxima variabilidad se evidencia en invierno en las localidades de Corrientes y Tucumán, alcanzando valores de σ_n superiores a 4°C . Campinas, es la estación con menor variabilidad interdiurna de T_n , donde los valores de σ_n oscilan en torno a los 2°C durante todo el año, aunque los máximos valores se alcanzan en los meses de mayo y junio.

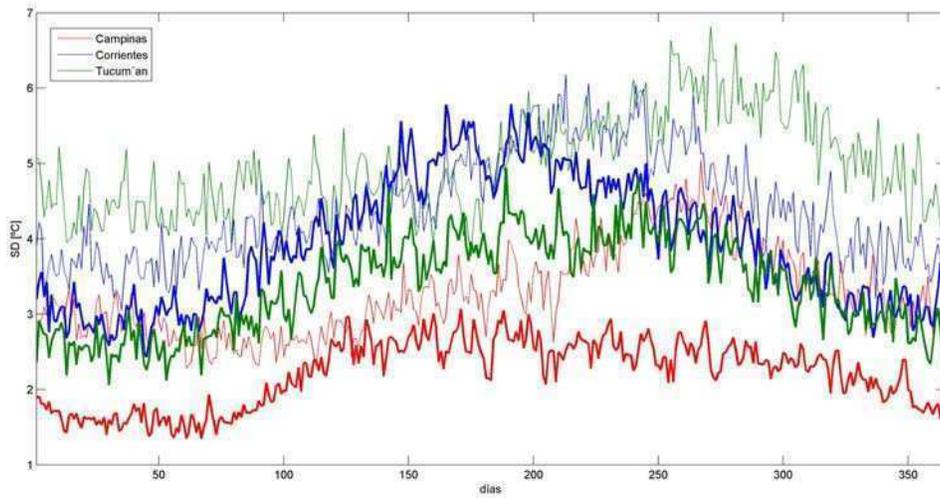


Figura 1.3. Marchas anuales de los desvíos estándar (SD) de T_x (línea fina) y T_n (línea gruesa) para Campinas, Corrientes y S.M. de Tucumán.

Región Central. (Pilar, Buenos Aires, Pergamino y Santa Rosa)

En esta región la estructura térmica anual es homogénea (figura 1.4) especialmente en el comportamiento de la temperatura máxima donde ésta muestra valores medios superiores a 30°C en el período estival. El rango anual de T_x es aproximadamente de 16°C en todas las estaciones, excepto en Santa Rosa donde se registra una amplitud anual mayor a 19°C . En cuanto a la temperatura mínima el rango anual es del orden de 13°C , excepto en Santa Rosa donde esta amplitud es de 16°C . Los valores medios extremos de T_n varían entre 17°C y 4°C .

Siguiendo con el análisis de la variabilidad a escala diaria en la región central, los máximos valores de los desvíos de la temperatura mínima se alcanzan en la época invernal, así en todas las localidades este valor es cercano a 4.5°C , mientras que σ_x muestra los máximos valores en primavera, siendo en magnitud similares a los alcanzados por la temperatura mínima.

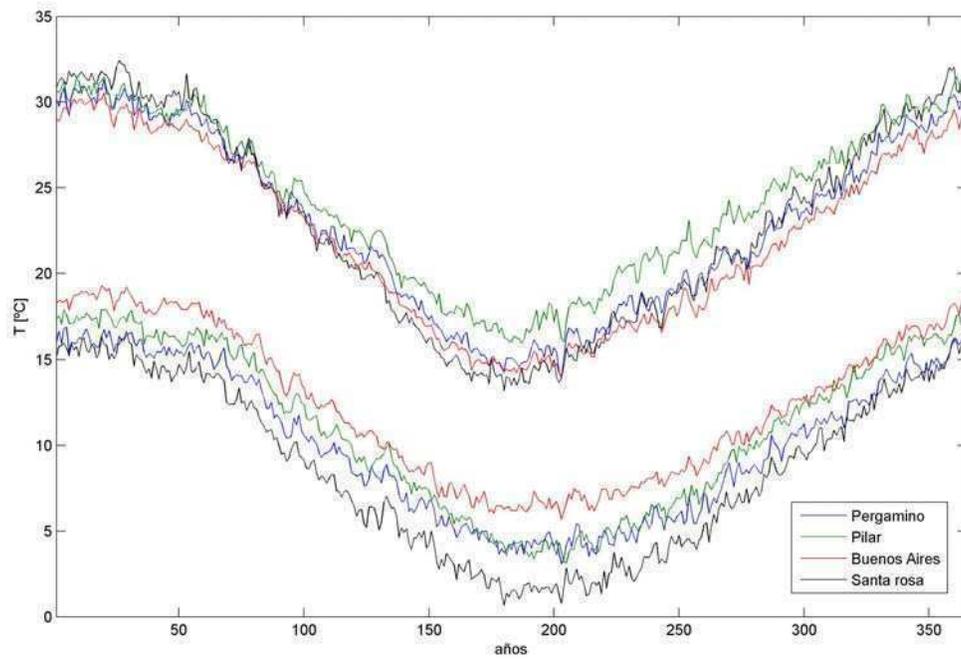


Figura 1.4. Marchas anuales de T_x y T_n para Pergamino, Pilar, Santa Rosa y Buenos Aires para los respectivos períodos completos de medición.

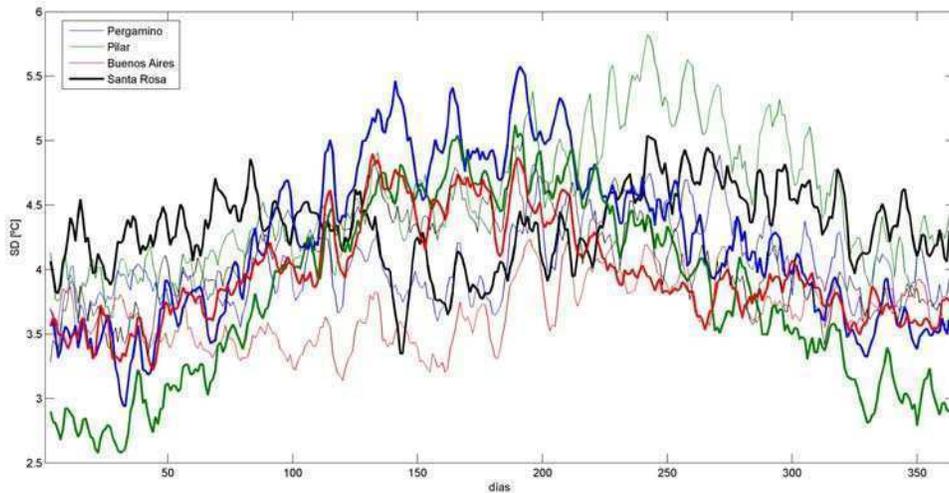


Figura 1.5. Marchas anuales de los desvíos estándar de T_x (línea fina) y T_n (línea gruesa) para Pergamino, Pilar, Santa Rosa y Buenos Aires [promedios móviles cada 5 días].

Región Sur. (Río Gallegos)

Las marchas anuales para las temperaturas en Río Gallegos (*figura 1.6*) muestran un rango anual para T_x de 16°C , mientras que para T_n este es de 11°C . En esta localidad T_x toma valores de máximo de 19.5°C en verano, mientras que los mínimos invernales llegan hasta los 3°C . En cuanto a T_n los valores medios oscilan entre los 7°C y los -3.5°C .

Los valores de los desvíos asociados tanto a la temperatura máxima como a la mínima en esta región, tienen valores cercanos a los cuatro grados durante todo el año. Este resultado difiere con lo observado en las otras regiones, en las cuales las variaciones interdiurnas muestran una onda anual definida.

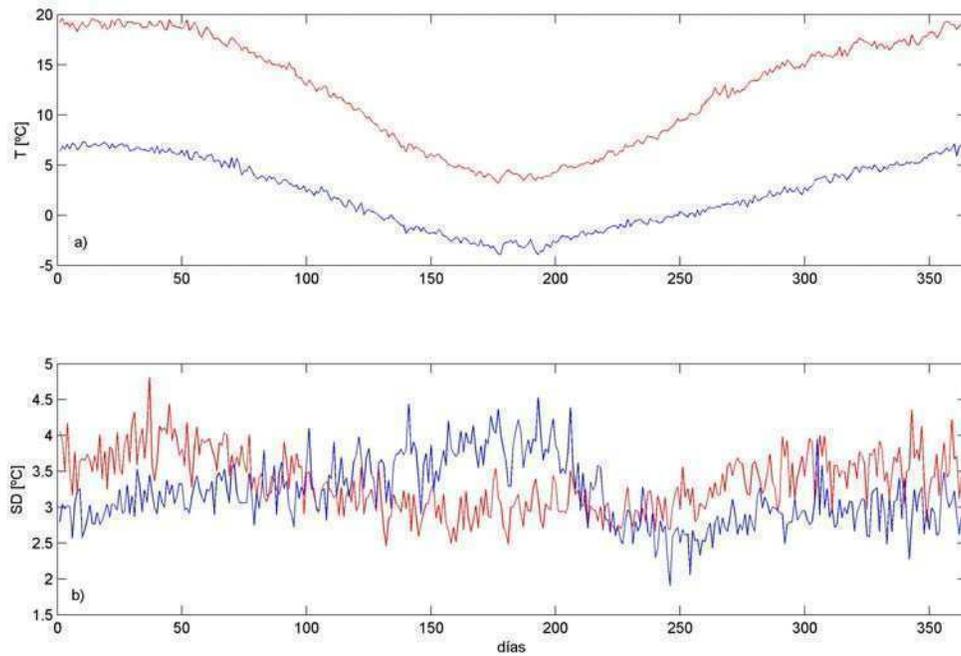


Figura 1.6. Marchas anuales de T_x , T_n , σ_x y σ_i para Río Gallegos.

Finalmente se puede concluir, que en general para las ocho estaciones de referencia la diferencia de fase entre las marchas de los valores medios y los desvíos evidencian que la intensidad de las irrupciones de aire frío y caliente es mayor en invierno.

Otra característica sobresaliente se observa en las marchas anuales de los desvíos estándar en Río Gallegos. Éstas poseen poca variabilidad durante todo el año, con algunas perturbaciones sobre la temperatura mínima en invierno, evidenciando la permanente presencia de una región, que aunque tiene propiedades baroclínicas, muestra la uniformidad de los sistemas que gobiernan la región.

Base de datos regional

En orden de obtener una amplia cobertura espacial, se utiliza en este trabajo una base de datos regional provista por el Servicio Meteorológico Nacional y el Proyecto CLARIS. Esta base de datos aunque cubre menor periodo que las estaciones de referencia descritas anteriormente cumple con la condición de tener una cantidad y calidad suficiente de

información diaria para obtener una estimación estable de clústeres (En este caso, más de 20000 valores diarios). Esta base de datos contiene información de temperatura máxima y mínima diaria en estaciones de Argentina, Brasil, Paraguay, Uruguay y Chile (tabla 1.2).

Pais	label	lat	lon	inicio	fin	Lon
Py	Villarica	-26.15	236.43	1956	1999	-56.43
Py	68	-23.49	240.22	1950	1999	-60.22
Uy	La Estanzuela	-34.27	237.5	1960	2002	-57.5
Ch	Arica	-18.12	290.48	1967	2005	-69.52
Ch	Antofagasta	-23.15	290.45	1967	2005	-69.55
Ar	Bahia Blanca	-38.44	242.1	1956	2006	-62.1
Ar	Jujuy	-24.23	245.5	1967	2006	-65.5
Ar	Salta	-24.51	245.29	1956	2006	-65.29
Ar	Las Lomitas	-24.42	240.35	1956	2006	-60.35
Ar	Iguazu aero	-25.44	234.28	1961	2004	-54.28
Ar	Sgo. Del Estero	-27.46	244.18	1956	2006	-64.18
Ar	Formosa	-26.12	238.14	1962	2006	-58.14
Ar	Corrientes	-27.27	238.46	1961	2006	-58.46
Ar	Posadas	-27.22	235.58	1956	2006	-55.58
Ar	La Rioja	-29.23	246.49	1956	2006	-66.49
Ar	Ceres	-29.53	241.57	1956	2006	-61.57
Ar	P de los libres	-29.41	237.09	1956	2006	-57.09
Ar	Sauce Viejo	-31.42	240.49	1958	2006	-60.49
Ar	Parana	-31.47	240.29	1956	2006	-60.29
Ar	Monte Caseros	-30.16	237.39	1959	2006	-57.39
Ar	Concordia	-31.18	238.01	1962	2006	-58.01
Ar	San Martin Mza	-33.5	248.52	1956	2006	-68.52
Ar	Mendoza	-32.5	248.47	1959	2006	-68.47
Ar	Villa Reynolds	-33.44	245.23	1956	2006	-65.23
Ar	Marcos Juarez	-32.42	242.09	1956	2006	-62.09
Ar	Rosario	-32.55	240.47	1950	2006	-60.47
Ar	Guauguaychu	-33	238.37	1956	2006	-58.37
Ar	Malargue	-35.3	249.35	1956	2006	-69.35
Ar	Laboulaye	-34.08	297.38	1950	2006	-62.62
Ar	Junin	-34.33	240.55	1958	2006	-60.55
Ar	9 de julio	-35.27	240.53	1950	2006	-60.53
Ar	Ezeiza	-34.49	238.32	1956	2006	-58.32
Ar	Palomar	-34.36	238.36	1956	2006	-58.36
Ar	Santa Rosa	-36.34	244.16	1951	2006	-64.16
Ar	Cnel. Suarez	-37.26	241.53	1956	2006	-61.53
Ar	Dolores	-36.21	237.44	1956	2006	-57.44

Ar	Mar del Plata	-37.56	237.35	1956	2006	-57.35
Ar	Neuquen	-38.57	248.08	1959	2006	-68.08
Ar	Esquel	-42.56	251.09	1961	2006	-71.09
Ar	Trelew	-43.12	245.16	1956	2006	-65.16
Ar	Rio Gallegos	-51.37	249.17	1956	2006	-69.17
Uy	Rocha	-34.29	234.18	1960	2002	-54.18
Uy	Artigas	-30.23	236.3	1960	2002	-56.3
Br	Bague	-31.23	306.7	1961	1997	-53.3
Br	Porto Alegre	-30	309.11	1951	1996	-50.89
Br	Santa Maria	-29.43	307.42	1961	1996	-52.58
Br	Curitiba	-25.31	311.11	1951	1997	-48.89
Br	Santos	-23.56	314.18	1951	2000	-45.82
Br	Sao Paulo	-23.37	314.39	1951	1997	-45.61
Br	Campinas	-23	313.08	1951	1997	-46.92
Ch	Pto Montt	-41.15	287.57	1967	2005	-72.43
Ch	Pta. Arenas	-53	290.3	1967	2005	-69.7
Ch	Stgo- Qta Normal	-33.15	290.36	1968	2005	-69.64

Tabla 1.2 Descripción, ubicación geográfica y período de observaciones para las estaciones de la base de datos regional.

1.3 Análisis de Consistencia

Antes de comenzar el análisis que comprende este estudio se efectuó un análisis de consistencia básica en las series diarias de temperatura máxima y mínima (**T_x** y **T_n** respectivamente) siguiendo, entre otras, las recomendaciones de la guía de control de calidad de datos climatológicos de superficie publicados por la Organización Meteorológica Mundial en el marco del programa mundial de datos climáticos (1984).

La primer acción en este sentido consistió en estandarizar el formato de los archivos de datos, ya que se encontró que algunos de ellos poseían valores aumentados en un factor 10 con respecto a la escala centígrada, es decir, para un valor de 25.2° C, en el archivo original se leía el valor 252. Esta diferencia sistemática se resolvió dividiendo por el factor a las series con esta característica.

Otra diferencia detectada en las series fue la simbología utilizada para marcar los datos ausentes. Entre estos códigos se hallaron símbolos como 0-, -999.9, 999.9 e incluso en

algunos archivos las fechas de datos ausentes se omitieron sistemáticamente. Cabe mencionar que también se encontraron valores como -0 ó 99.9 los cuales se clasificaron como ausentes. Conforme a esto se decidió uniformizar el código de datos faltantes con el valor numérico 999.9. Además los valores rechazados por el análisis de consistencia que se detalla a continuación fueron reemplazados por este valor.

Como segunda medida se analizó la presencia de valores inconsistentes y se tomaron decisiones de acuerdo al tipo de esta inconsistencia

El primer paso fue clasificar los días en que $T_x < T_n$. Los registros que cumplieron con esta condición fueron marcados como ausentes.

En segundo lugar se encontró la ocurrencia sistemática de secuencias con más de diez días seguidos donde la temperatura mínima fue igual a cero, en tal caso estas secuencias se asumieron como un error en la simbolización del código de dato ausente o un desperfecto en el termómetro de mínima y por consiguiente estas secuencias fueron computadas como dato faltante.

Finalmente se analizó la presencia de “outliers” a partir de un análisis de consistencia interna de las series. Un “outlier” es una observación que se encuentra a una distancia anormal de otros valores en una muestra escogida al azar de una población. Según esta definición, es necesario decidir que será considerado como anormal. Para esto se consideraron dos criterios.

1- Se separaron los valores que se encuentran a una distancia de $\pm 4\sigma$ de la media. Estos son valores con una escasa probabilidad de ocurrencia, por esto se decidió realizar un análisis detallado de los datos clasificados según este criterio para discernir si se tratan de verdaderos extremos o de un error en la adquisición.

2- A partir del análisis de las diferencias de temperatura entre dos días consecutivos es posible determinar la presencia de valores incoherentes. Para esto se calculó la diferencia climática, es decir el valor medio de la diferencias día a día. Los valores dudosos fueron clasificados como aquellos que superaron cinco veces la desviación estándar de estas diferencias.

En ambos casos, a los días clasificados como dudosos se les efectuó un control, donde se analizó la evolución de la temperatura máxima y mínima en los días anteriores y posteriores a la fecha cuestionada. A partir de esto es posible determinar si los valores tienen consistencia física, por ejemplo el pasaje de sistemas frontales intensos, olas de calor, etc. O bien si estos no se pueden atribuir a ningún proceso físico conocido se procedió a señalar estos valores con el correspondiente símbolo de datos ausentes.

Luego de la consistencia inicial se procedió a evaluar la existencia de datos ausentes. Dada la longitud de los registros analizados (mayores a 67 años), se encontró en las ocho estaciones datos ausentes. Por consiguiente se procedió a cuantificar la información faltante (tabla 1.3), a partir de esto se definió un criterio para optimizar el uso de esta. Así, los años que contaban con menos del 25% de los datos fueron descartados de los análisis anuales y estacionales, mientras que no se eliminaron estos años en la clasificación objetiva realizada a las variables conjuntas.

1.4 Análisis de inhomogeneidades en las series temporales

Dada la longitud de los períodos de las series estudiadas, es necesario realizar un análisis de homogeneidad sobre estas, para conocer el efecto de posibles cambios sistemáticos en los valores medidos y adoptar una metodología que minimice los errores en el diagnóstico de las variaciones seculares presentes.

Las inhomogeneidades absolutas en los promedios de las series de temperatura se pueden deber a efectos naturales, como es el caso de los saltos climáticos (Yamamoto, et al 1985). Otro factor perturbador de las series de temperatura son los agentes antropogénicos. Estos cambios se deben principalmente a dos factores; 1) el crecimiento de las ciudades que circundan la estación meteorológica, imponiendo un incremento en los valores registrados y 2) la relocalización de la estación por razones operativas generalmente del núcleo urbano a los aeródromos más cercanos.

Años	Corrientes		Gallegos		Santa Rosa		Pergamino		Pilar		Tucumán		O.C.B.A.		Campinas	
	Tx	Ti	Tx	Ti	Tx	Ti	Tx	Ti	Tx	Ti	Tx	Ti	Tx	Ti	Tx	Ti
1890																
1892																
1894																
1896																
1898																
1900																
1902																
1904																
1906																
1908																
1910																
1912																
1914																
1916																
1918																
1920																
1922																
1924																
1926																
1928																
1930																
1932																
1934																
1936																
1938																
1940																
1942																
1944																
1946																
1948																
1950																
1952																
1954																
1956																
1958																
1960																
1962																
1964																
1966																
1968																
1970																
1972																
1974																
1976																
1978																
1980																
1982																
1984																
1986																
1988																
1990																
1992																
1994																
1996																
1998																
2000																
2002																

Tabla 1.3. Descripción de datos faltantes para las estaciones de referencia. En verde se señalan años con más de 100 días faltantes y en rojo años sin datos.

Con referencia a este tema Minetti y Vargas (1997) estudiaron las inhomogeneidades presentes en series de temperatura del Noroeste Argentino, encontrando que la magnitud de los errores en las observaciones (ya sea por relocalización de estaciones o cambios en la estimación de las temperaturas medias) pueden conducir a resultados erróneos en cuanto al estudio de las variaciones climáticas a largo plazo. Además encontraron que el calentamiento Urbano-Industrial afecta fundamentalmente a las series de temperaturas mínimas medias, siendo este efecto mayor durante el invierno.

Las series climáticas temporales de resolución temporal mensual y anual tienen establecidos numerosos métodos estadísticos para determinar su homogeneidad. En Peterson, et al (1998) se muestra una reseña completa de estas metodologías. Para series climáticas diarias estos métodos son escasos y en general se trata de derivar en variables de escala mensual o anual a partir de los valores diarios para aproximar la fecha en que se produce un salto en los valores medios (Wijngaard, et al 2003).

Conforme a esto es de gran importancia el conocimiento de documentación (metadata) que detalle información sobre cambios en la ubicación de la estación, cambios en el tipo de instrumental, etc. A partir de esta referencia es posible inferir sobre la presencia de inhomogeneidades absolutas, especialmente útil en las series analizadas en este estudio, ya que la longitud del período comprendido no permite un análisis de coherencia con estaciones de la misma región climática.

A partir de la información suministrada por la oficina del Banco de Datos del Servicio Meteorológico Nacional, las estaciones Corrientes y Río Gallegos registraron cambios en la ubicación del emplazamiento de la estación de medición.

La estación Corrientes, la cual se encontraba emplazada en esta ciudad capital fue declarada operativa desde el 1/1/1873 hasta fines del año 1969. En el mes de noviembre de 1961 se instaló la estación meteorológica “Corrientes aero” en el aeropuerto de esta ciudad siendo esta estación la que continúa registrando variables de superficie hasta la actualidad. En referencia a esto, en el presente trabajo la serie analizada está compuesta por los registros de la estación urbana hasta el año 1961, mientras que desde el año 1962 en adelante los valores corresponden a la estación emplazada en el aeropuerto.

La estación Río Gallegos comenzó a operar en el núcleo urbano de esta ciudad en el año 1896. A partir del año 1945 fue trasladada hacia el aeropuerto local, donde funciona actualmente.

1.4.1 Caso Corrientes

Dado que en el período de 1961-1969 en la localidad de Corrientes funcionó simultáneamente la estación urbana y rural, es posible realizar un análisis comparativo para determinar la coherencia entre estas dos estaciones. A partir de los valores diarios de T_x y T_n de las series “Corrientes ciudad” y “Corrientes Aero”, se calcularon los promedios para cada día del año, obteniéndose las marchas anuales para estas dos estaciones.

Luego con el objeto de determinar si existe un cambio en los valores medios de estas series, para cada temperatura extrema se calculó la diferencia entre las marchas anuales definidas como:

$$\Delta T_i = T_{ciudad(i)} - T_{aero(i)} \quad (1.1)$$

donde $i=1, \dots, 365$ días del año

En la figura 1.7 se muestran las diferencias entre las marchas anuales de T_x y T_n de ambas estaciones en el período de solapamiento. Aquí se observa claramente un calentamiento impuesto por la urbanización en las dos variables durante todo el año.

La diferencia promedio para la temperatura máxima es de 1.3°C , siendo ésta mayor en la época de otoño y primavera donde las diferencias alcanzan valores medios de 2°C . Analizando la temperatura mínima, se encontró que la diferencia media anual entre el aeropuerto y la ciudad es de 1.6°C . Además esta variable es más sensible al efecto de calentamiento urbano en el invierno, donde se observan diferencias promedio superiores a los 2°C .

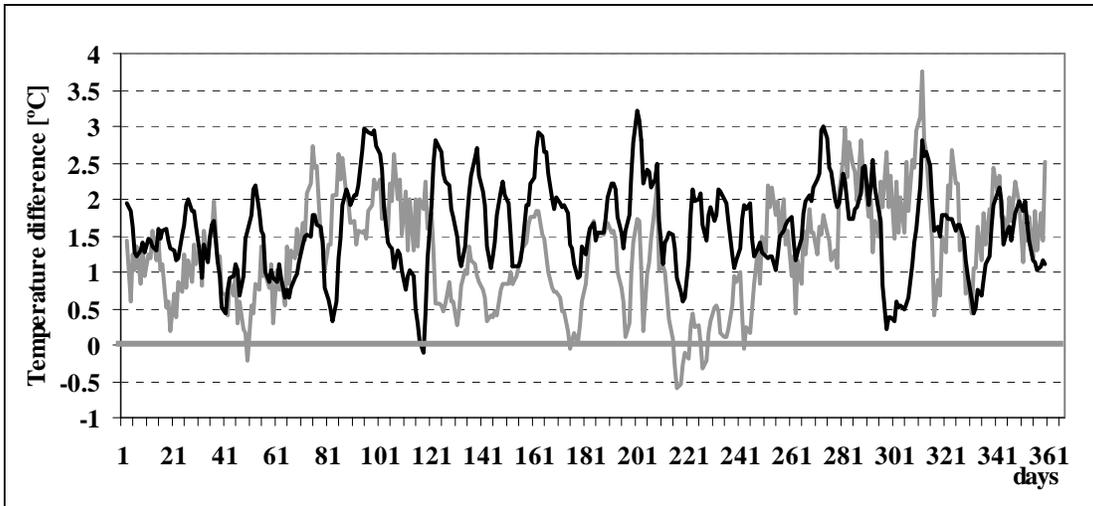


Figura 1.7 Diferencias de las marchas anuales de T_x y T_n en Corrientes ($\Delta T = T_{\text{ciudad}} - T_{\text{aero}}$) entre la estación urbana y la rural en el período de solapamiento 1961-1969. [Promedios móviles de 5 días]. En gris se indica T_x y en negro T_n .

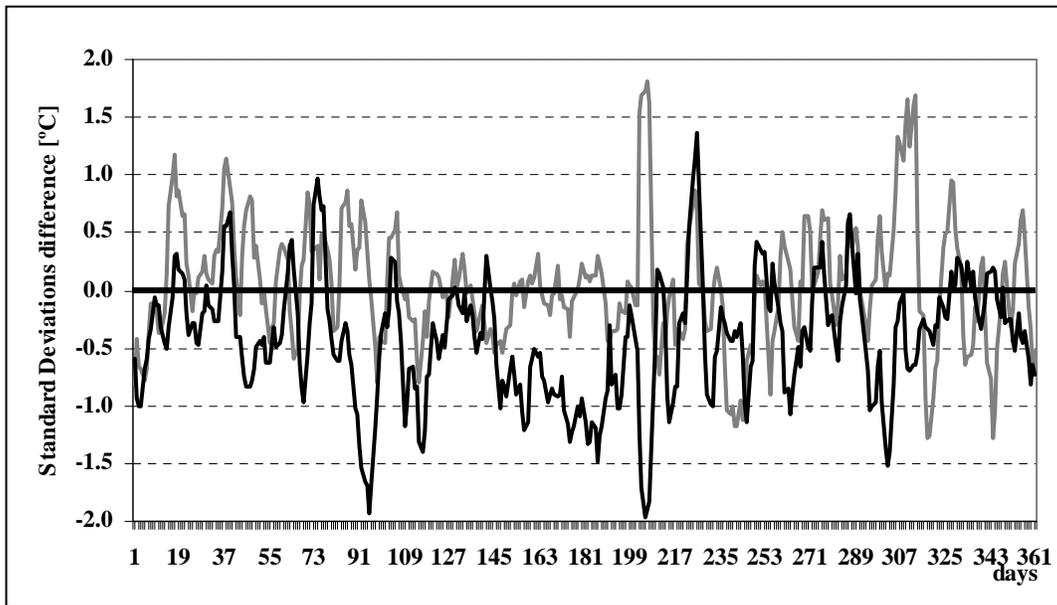


Figura 1.8 Diferencias de las marchas anuales de los desvíos estándar (σ_T) de T_x y T_n en Corrientes ($\Delta \sigma_T = \sigma_{T_{\text{ciudad}}} - \sigma_{T_{\text{aero}}}$) entre la estación urbana y la rural en el período de solapamiento 1961-1969. [Promedios móviles de 5 días]. En gris se indica σ_x y en negro σ_n .

Para analizar la variación interanual de las temperaturas extremas se estudiaron las marchas anuales de los desvíos estándar (σ_t). En la figura 1.8 se muestran las diferencias entre las marchas de σ_t de la estación urbana y la estación rural. Aquí se observa una menor variación anual en la temperatura mínima de la ciudad, especialmente en la época invernal, donde las diferencias son mayores a 0.5° C. En cuanto a las variaciones interanuales de la temperatura máxima, no se observa un desplazamiento sistemático en los valores de los desvíos, con lo cual se puede inferir que σ_{T_x} no se ven afectadas por la urbanización.

Con el fin de determinar si los procesos físicos de escala sinóptica, asociados a la variación interdiurna son modificados por la urbanización se analizó la función de autocorrelación de las series de temperaturas extremas diarias en las dos localidades.

Para discernir si estas funciones representan al mismo proceso se compararon las funciones obtenidas con aquellas asociadas a un proceso Markoviano ($r_k=r_1^k$). Si se asume que el proceso tiene memoria, es decir es un proceso de ruido rojo, el error estándar de r_k esta dado por

$$stderror(r_k) = \sqrt{\left(\frac{1}{N}\right) \left[1 + 2 * \sum (r_i)^2\right]} \quad \text{con } i=1, \dots, k-1 \quad (1.2)$$

donde k es el lag y N el número de datos.

En la figura 1.9 se muestra la función de autocorrelación para las series diarias de temperaturas máxima y mínima. Analizando el primer coeficiente de la función, quien caracteriza el proceso estocástico asociado al modelo Markoviano, se observa que no existen diferencias para ninguna de las temperaturas. Este resultado muestra que la variación interdiurna tanto de T_x como de T_n no se ve afectada por efectos ocasionados por la urbanización.

Analizando más detalladamente el autocorrelograma asociado a T_x se observa que en ambas estaciones los procesos corresponden al mismo modelo Markoviano si se considera variaciones de T_x menores a 10 días.

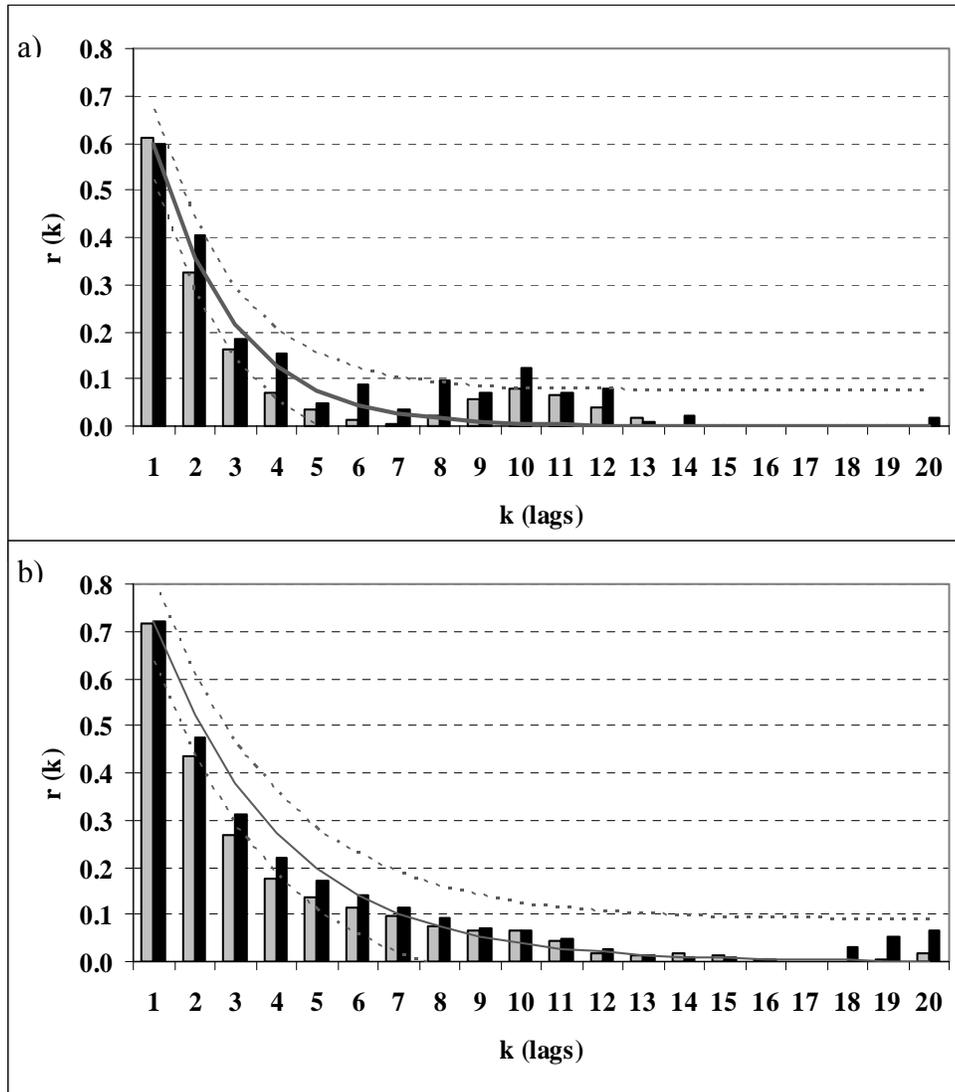


Figura 1.9 Función de autocorrelación para a) T_x' y b) T_n' diarias en la estación Corrientes ciudad (gris) y Corrientes aeropuerto (negro) y proceso Markoviano asociado con su intervalo de confianza (lineas) en el período 1961-1969.

Para T_n las variaciones entre dos y cuatro días presentan una menor relación en la estación urbana comparada con la estación rural y el proceso Markoviano que rige a éstas. Esto puede ser así debido a que la varianza en la temperatura mínima es menor con respecto a la ciudad, como se mostró en la descripción de la figura 1.8. Para variaciones de período mayor a cinco días los procesos están asociados al mismo modelo.

Con estos resultados se concluye que el cambio de localización de la estación de medición afecta en gran medida a los valores medios de estas series temporales, imponiendo un corrimiento sistemático de las mediciones. Luego en menor medida se observan diferencias en los desvíos de la temperatura mínima, especialmente en los meses de invierno. Finalmente se encuentra que no se modifican los procesos estocásticos asociados a las series diarias de temperatura. Este resultado implica que los procesos sinópticos que conforman la variación a escala interdiurna a semanal no se ven modificados por el efecto urbano.

Dado que se desea eliminar el corrimiento inducido en los valores medios, y ya que el análisis sobre las oscilaciones de baja frecuencia se realizará sobre las anomalías de temperatura, se decidió calcular estas anomalías respecto al período urbano y rural. En este caso se tomó como período urbano a los registros comprendidos entre los años 1894-1961, mientras que el período rural comprende los años 1962-2004.

Así se obtuvieron las anomalías diarias de acuerdo a:

$$Tx'_{jkl} = Tx_{jkl} - \overline{Tx}_{jk} \quad (1.3)$$

$$Ti'_{jkl} = Ti_{jkl} - \overline{Ti}_{jk} \quad (1.4)$$

Donde Tx'_j y Tn'_j es el valor de la anomalía de temperatura máxima y mínima respectivamente para el día j , mes k y año l ; Tx_{jkl} y Tn_{jkl} es el valor de temperatura del día j , mes k y año l y

$$\overline{Tx}_{jk} = \frac{1}{n} \sum_{l=1}^n Tx_{jkl} \quad (1.5)$$

$$\overline{Ti}_{jk} = \frac{1}{n} \sum_{l=1}^n Ti_{jkl} \quad (1.7)$$

Son los promedios climáticos de temperatura máxima y mínima del día j y mes k y n es la cantidad de años de la serie de cada subperíodo.

En cuanto a la serie anual de anomalías se calculó la anomalía media del año l como:

$$Tx^*_l = \frac{1}{365} \sum_{m=1}^{365} Tx'_m \quad Ti^*_l = \frac{1}{365} \sum_{m=1}^{365} Ti'_m \quad (1.8) \text{ y } (1.9)$$

Analizando la marcha de las anomalías medias anuales (T_x^* y T_n^* en *figura 1.10*), se observa claramente la diferencia entre la serie donde se calcularon las anomalías diarias respecto al promedio del período 1894-2004 y la serie donde se calcularon respecto a los promedios de los distintos subperíodos. En la serie a) se observa un período caliente antes de 1960 asociado al efecto de calentamiento urbano, mientras que en la segunda parte del registro se muestran anomalías negativas en casi la totalidad del subperíodo. Este es claramente un efecto inducido por el desplazamiento de la estación en el año 1961 y el análisis de esta serie puede llevar a un diagnóstico erróneo de oscilaciones de baja frecuencia.

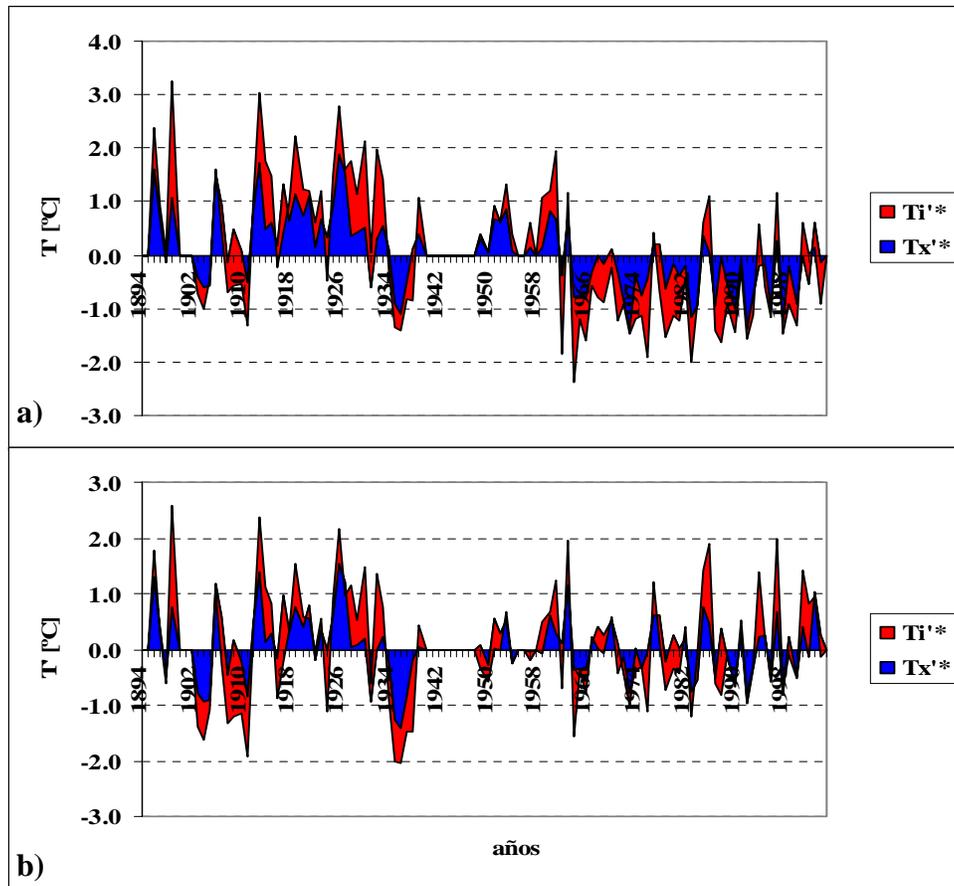


Figura 1.10 Promedio anual de las anomalías de temperatura máxima y mínima [T_x^* y T_n^*] para a) la serie original y b) la serie homogénea.

En la serie b) que se obtiene al homogeneizar los registros, el efecto antropogénico estudiado no se evidencia. Así la serie de anomalías diarias asociada a ésta será la utilizada en los análisis subsiguientes.

1.4.2 Caso Río Gallegos

Esta estación comenzó a operar en el año 1896 en el núcleo urbano hasta el año 1945, donde fue trasladada hacia el aeropuerto local. Lamentablemente no se cuenta con información simultánea de ambas estaciones. Por ello, para determinar si la relocalización indujo un desplazamiento de los valores medios, se calcularon las anomalías anuales T_x^* y T_n^* en la serie original y en la serie donde las anomalías diarias se calcularon respecto a los períodos anterior y posterior a la relocalización, como se indicó en la sección anterior para el caso de Corrientes. A partir de estas series se calcularon las diferencias entre ambas marchas anuales de T^* (Figura 1.11). En este caso al analizar estas diferencias se observa un salto en el año 1945, coincidente con el traslado de la estación hacia el aeropuerto. El efecto inducido en la serie corresponde a un calentamiento, siendo en promedio de 0.7 °C para la T_x y 1.1 °C en T_n .

Al igual que en la serie de Corrientes se ajustó esta diferencia sistemática calculando las anomalías diarias en ambas variables con relación a las medias de las muestras correspondientes al período urbano y suburbano.

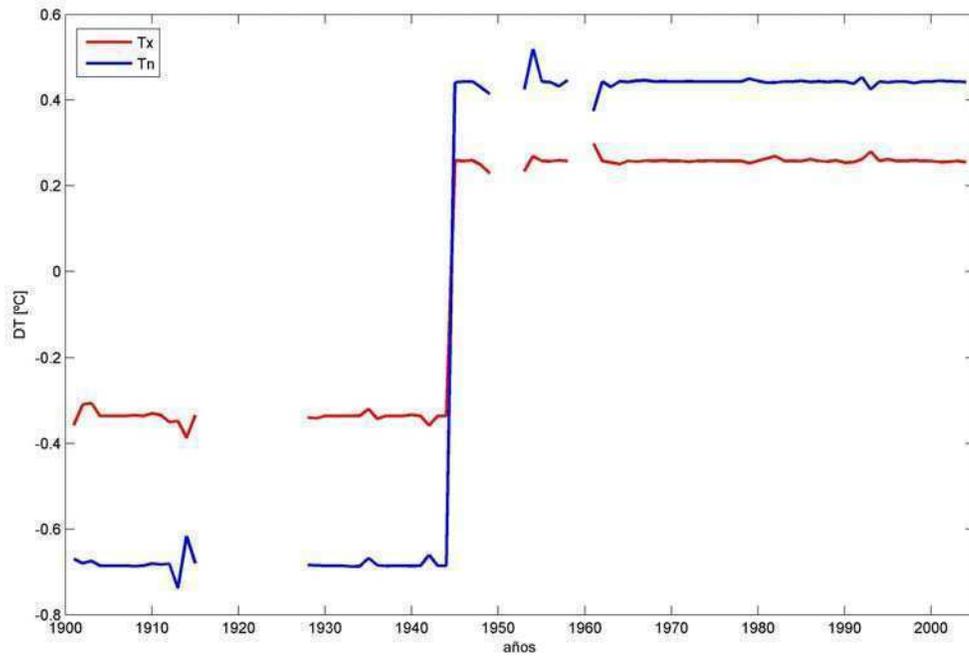


Figura 1.11. Diferencias de T^* entre la serie original y la serie homogénea; en Río Gallegos. En rojo se indica ΔT_x y en azul ΔT_n .

1.4.3 Efecto de calentamiento urbano

Se han realizado numerosos trabajos sobre las características térmicas de las áreas urbanas (Chandler T., 1965; Jones P, et al 1989, etc.), donde se muestra que existe un gran contraste con las zonas rurales circundantes. En general estas diferencias térmicas se deben a la interacción de los siguientes factores:

- I- Cambios en el balance de radiación debidos a la composición atmosférica.
- II- Cambios en el balance de radiación debidos al albedo y la capacidad térmica.
- III- Producción de calor por actividades humanas.

El efecto neto de estos procesos térmicos se traduce en un incremento de la temperatura urbana respecto a las regiones rurales circundantes. En la sección 1.4.1 se mostró este efecto en la localidad de Corrientes, donde se mostró que este incremento fue superior a 1°C para las dos temperaturas extremas.

Aunque no es posible determinar exactamente si los cambios de temperatura son debidos al crecimiento de los asentamientos urbanos y/o a efectos naturales, se ha indicado que el crecimiento de una ciudad está acompañado de un aumento de la temperatura media anual. En relación a este tema Karl, T. (1988) encontró una relación exponencial entre la intensidad media anual de la isla de calor con la población. En Argentina Barros y Camilloni (1994) y Camilloni y Barros (1997) realizan un extenso análisis en diversas estaciones de Argentina subtropical y en especial sobre Buenos Aires, encontrando que la dependencia del exceso urbano de temperatura con la población es muy similar al de Australia, validando la relación encontrada por Karl.

En la figura 1.12 se muestra el aumento de la población en la Ciudad de Buenos Aires y el Gran Buenos Aires y la temperatura mínima media anual medida en el Observatorio Central Buenos Aires durante el siglo veinte. Durante este período la ciudad de Buenos Aires muestra un crecimiento sostenido hasta la década de 1950, donde la población de ésta se estaciona en 3 millones de habitantes. Coincidente con este proceso, la población del conurbano comienza un crecimiento desde 1.7 millones de habitantes en el censo de 1947 hasta 8.7 millones en 2001. Resumiendo, la población de este conglomerado urbano muestra un crecimiento exponencial durante casi la totalidad del siglo veinte.

Este aumento de la población también se reconoce en Campinas, donde la población de esta localidad fue estimada en el año 2004 en más de un millón de habitantes. Así mismo, cabe destacar la cercanía de esta localidad con el conglomerado urbano de San Pablo, donde la cantidad de habitantes en el 2001 se censó en 10.8 millones.

Finalmente, dado que este efecto conocido induce una tendencia de origen antropogénico, se decide extraerla de la series de valores diarios. Para esto se obtiene la recta que mejor aproxima esta variación a escala diaria mediante cuadrados mínimos. Una vez conocida esta relación, se extrae la pendiente que impone el aumento de los valores medios. Finalmente se toman los apartamientos respecto a la marcha anual de la nueva serie sin tendencias como las anomalías diarias de la serie sin tendencia.

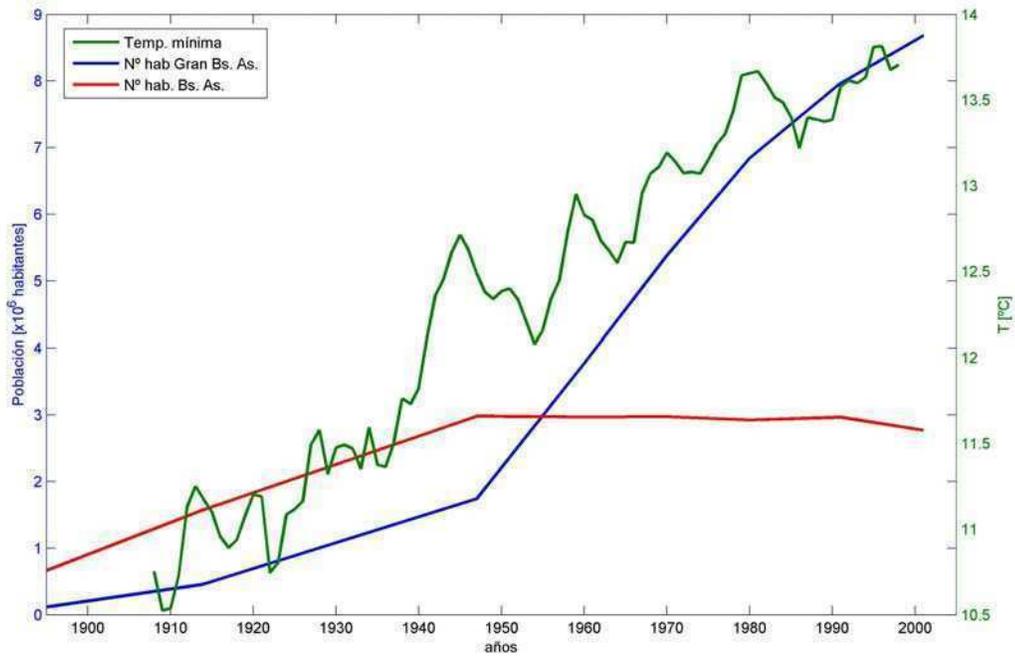


Figura 1.12. Temperatura mínima media anual y crecimiento de la población en la Ciudad de Buenos Aires y alrededores (fuente INDEC 2001).

Cabe mencionar, que esta variación secular además de estar producida por el factor urbano puede deberse a efectos naturales desconocidos, con lo cual se puede introducir un error en el diagnóstico de éstos.

En la *figura 1.13* se muestran las diferencias entre las series de anomalías medias anuales en Buenos Aires con evidencias del calentamiento urbano y aquellas series donde se filtra este efecto mediante el método propuesto. Aquí se observa que en la serie original, la señal que rige el crecimiento urbano domina claramente con respecto a otras fluctuaciones naturales que puedan regir el comportamiento de las series de temperatura extremas.

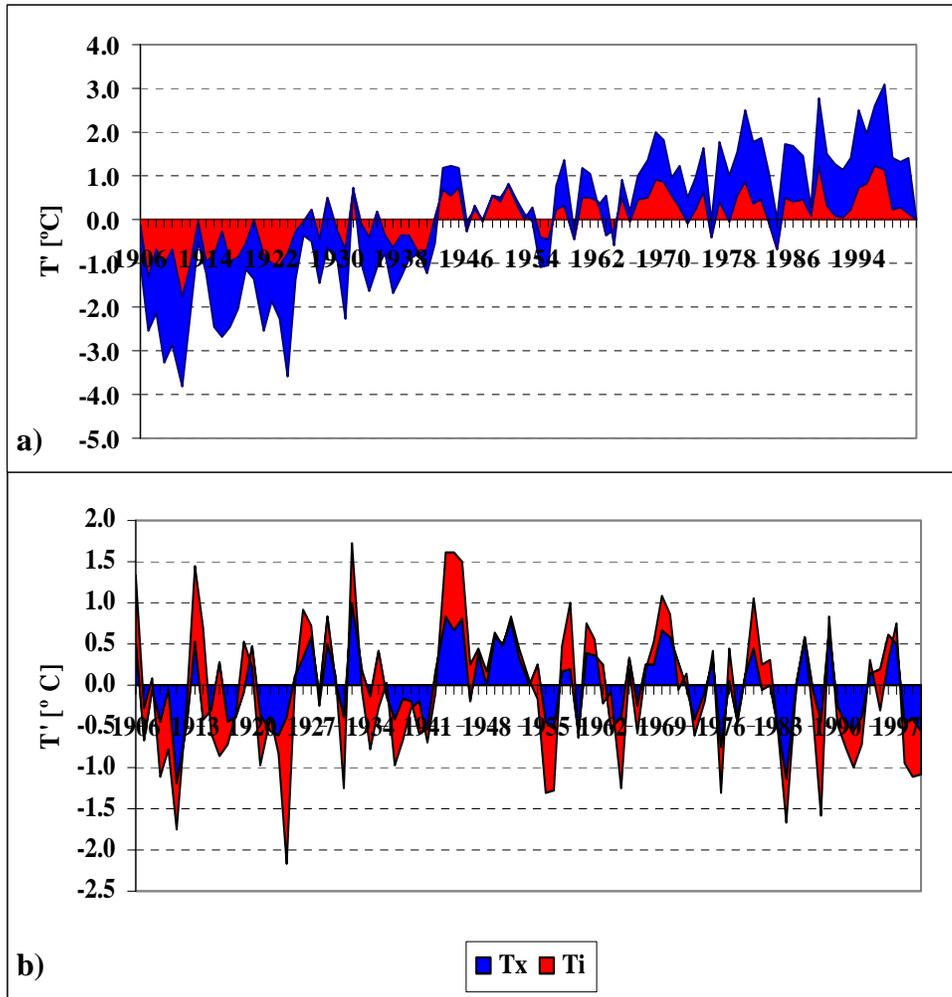


Figura 1.12 Promedio anual de las anomalías de temperatura máxima y mínima [Tx^{*} y Tn^{*}] para a) la serie original y b) la serie sin tendencia en OCBA

1.5 Métodos

1.5.1 Métodos de análisis espectral

Inicialmente los problemas de las series temporales pueden ser clasificados en dos grandes grupos. Aquellos que requieren alguna forma de construcción de modelo teórico y aquellos que requieren un análisis de la respuesta en frecuencia. Inevitablemente estas dos categorías tienen mucha información en común (Jenkins and Watts 1968).

Dado que en este trabajo tiene como objetivo principal tratar a estos problemas sobre las series de referencia se propone utilizar varias aplicaciones del análisis espectral. Por este

motivo en la siguiente sección se describen brevemente las metodologías utilizadas. Más información sobre diferentes aplicaciones del análisis espectral se puede encontrar en Jenkins and Watts (1968), Otnes and Enochson (1972), Båth M. (1974), Daubechies (1992), Foufola-Georgiu y Kumar (1995) y Torrence y Compo (1998).

1.5.2 Análisis Armónico

El análisis de Fourier es una técnica desarrollada por el matemático y físico francés Jean Baptiste Fourier (1768-1830) es una herramienta matemática utilizada para analizar funciones $f(t)$ periódicas a través de la descomposición de dicha función en una suma infinitesimal de funciones sinusoidales. Si consideramos una señal $s(t)$ que se especifica de manera discreta, la serie finita de Fourier se define como

$$s(t) = \frac{a_0}{2} + \sum_{n=0}^{N/2} (a_n \cos(i\omega t) + b_n \text{sen}(i\omega t)) \quad (1.10)$$

Donde el período $P = 2\pi/\omega$, y $a_0, a_1, \dots, a_i, \dots$ y $b_1, b_2, \dots, b_i, \dots$ son los denominados coeficientes de Fourier.

Conocida la función periódica $s(t)$, se calculan los coeficientes a_i y b_i del siguiente modo

$$\frac{a_0}{2} = \frac{2}{P} \sum_{-P/2}^{P/2} s(t) dt \quad (1.11)$$

$$a_i = \frac{2}{P} \sum_{-P/2}^{P/2} s(t) \cos(i\omega t) dt \quad (1.12)$$

$$b_i = \frac{2}{P} \sum_{-P/2}^{P/2} s(t) \text{sen}(i\omega t) dt \quad (1.13)$$

Por conveniencia se asume que N es igual a $2n$ e $i=1,2,3,\dots,N/2$. Como resultado se tiene que la señal $s(t)$ se puede descomponer en la suma de senos y cosenos cuyas frecuencias son múltiplos de o armónicos de la frecuencia fundamental ($f=1/N\Delta t$).

1.5.3 Método de Blackman –Tukey

Blackman y Tukey (1958), propusieron y analizaron un método donde se analiza en ventanas la función de autocorrelación de una serie temporal y después se calcula su transformada de Fourier para producir una estimación espectral. La principal razón para trabajar con ventanas de la función de autocorrelación $r_x(k)$ es que, para retardos grandes, las estimaciones son menos fiables dado que usan menos puntos en la estimación $(N-k)$. Para valores de k cercanos a N , la varianza de estas estimaciones es muy grande, por lo que estos deberían tener un menor peso. Por ejemplo, para el retardo $k = N-1$, la estimación de $r_x(k)$

$$\hat{r}_k(N-1) = \frac{1}{N} x(N-1)x(0) \quad (1.14)$$

consta de una sola muestra, lo que da una medida de la varianza poco fiable. El estimador de Blackman-Tukey es:

$$\hat{S}_{BT}(e^{jw}) = \sum_{k=-M}^M \hat{r}_k(k)w(k)e^{-jkw} \quad (1.15)$$

donde $w(k)$ es la ventana aplicada para reducir la contribución al periodograma de las estimaciones menos fiables. Se extiende desde $-M$ hasta M , con $M < N-1$. De esta manera, las estimaciones de $r_x(k)$ con mayor varianza son puestas a cero y, por tanto, la estimación espectral de potencia tendrá una varianza menor.

Con esta definición para $w(k)$, los límites del sumatorio anterior se pueden extender desde menos infinito a más infinito. Consecuentemente, la expresión equivalente en el dominio frecuencial para el estimador de Blackman-Tukey es:

$$\hat{S}_{BT}(e^{jw}) = \frac{1}{2\pi} \hat{S}_{per}(e^{jw}) * W(e^{jw}) \quad (1.16)$$

El efecto de aplicar una ventana a la secuencia de autocorrelación se refleja en un suavizado de la estimación del periodograma, decreciendo, así, la varianza de la estimación espectral a expensas de la reducción en resolución.

Aunque existe una considerable flexibilidad en la elección de la ventana, $w(k)$ debe poseer simetría conjugada para que $W(e^{jw})$ sea real y asegurar así que la estimación sea real. Además, la ventana debería tener una transformada de Fourier no negativa, $W(e^{jw}) \geq 0$, para que la estimación realizada sea no negativa.

1.5.4 Análisis espectral wavelet

El análisis wavelet es una herramienta que permite analizar variaciones del poder espectral en series temporales. En líneas generales, esta metodología permite descomponer una serie temporal en el espacio tiempo-frecuencia, es decir es posible determinar los principales modos de variabilidad y detectar como varían estos modos con el tiempo. Una completa descripción sobre la teoría del análisis wavelet se encuentra en Daubechies (1990, 1992), mientras que una completa descripción de la aplicación en geofísica puede ser encontrada en Foufola-Georgiu y Kumar (1995) y Torrence y Compo (1998). La descripción sobre los principales puntos teóricos de ésta metodología se realizó siguiendo éste último trabajo.

La transformada wavelet puede ser utilizada para analizar las series que contienen poder espectral no-estacionario para diferentes frecuencias. Se asume que la serie temporal X_n , tiene el mismo paso de tiempo para todo t (Δt constante) y $n=0, \dots, N-1$ observaciones. Para comenzar el análisis se utiliza una función wavelet $\psi_0(\eta)$ que depende de un parámetro temporal adimensional (η). Para que una función sea admisible como wavelet, debe tener media igual a cero y estar localizada tanto en el espacio de tiempo como en el de frecuencia (Farge 1992). Por ejemplo la función wavelet Morlet, consiste en una onda plana modulada por una función Gaussiana:

$$\psi_0(\eta) = \pi^{-1/4} e^{i\omega_0\eta} e^{-\eta^2/2} \quad (1.17)$$

donde ω_0 es una frecuencia adimensional.

La transformada wavelet continua de una secuencia de datos discreta (X_n) se define como la convolucion de X_n con respecto a $\psi_0(\eta)$

$$W_n(s) = \sum_{n'=0}^{N-1} X_{n'} \psi^* \left[\frac{(n'-n)\Delta t}{s} \right] \quad (1.18)$$

Donde (*) indica el complejo conjugado. A partir de variaciones en la escala wavelet “s” y de trasladar el índice temporal η , es posible construir un diagrama bidimensional que muestra el poder espectral para distintas frecuencia y la variación de este poder respecto del tiempo. Más detalles sobre la aproximación de la transformada wavelet continua se puede

encontrar en Kaiser (1994), realizando la convolución de la ecuación (1.18) N veces por cada escala, donde N es la longitud de la serie temporal. Con esto la transformada discreta de Fourier de X_n es

$$\hat{X}_k = \frac{1}{N} \sum_{n=0}^{N-1} X_n e^{-2\pi i k n / N} \quad (1.19)$$

donde $k=0, \dots, N-1$ es el índice de frecuencia. Dentro de los límites de continuidad, y por el teorema de convolución, la transformada wavelet es la inversa de la transformada de Fourier del producto

$$W_n(s) = \sum_{k=0}^{N-1} \hat{X}_k \psi^*(s\omega_k) e^{i\omega_k n \Delta t} \quad (1.20)$$

donde la frecuencia angular se define como

$$\omega_k = \begin{cases} \frac{2\pi k}{N\Delta t} : k \leq \frac{N}{2} \\ -\frac{2\pi k}{N\Delta t} : k > \frac{N}{2} \end{cases} \quad (1.21)$$

Utilizando (4) y una rutina de transformada de Fourier es posible calcular la transformada de wavelet continua para un s dado y todos los n simultáneamente.

Para asegurar que la transformada wavelet para cada escala “s” sea directamente comparable con las otras escalas y con las transformadas de otras series temporales, cada función wavelet en cada escala s es normalizada para tener unidades de energía;

$$\psi(s\omega_k) = \left(\frac{2\pi_s}{\Delta t} \right)^{1/2} \psi_0(s\omega_k) \quad (1.22)$$

Dado que la función $\psi_0(\eta)$ es en general compleja, la transformada wavelet $W_n(s)$ también es compleja. Por lo tanto la transformada puede ser dividida entre la parte real y la imaginaria, cuya amplitud es $|W_n(s)|$. Con estos elementos es posible definir el poder

espectral wavelet como $|W_n(s)|^2$. Así mismo, es posible comparar diferentes espectros wavelet a través de una normalización común del espectro wavelet. Para series asociadas a procesos de ruido blanco el valor esperado es σ^2/n , donde σ^2 es la varianza. Además para procesos de ruido blanco el valor esperado para la transformada wavelet es $|W_n(s)|^2 = \sigma^2$ para todo n y s . Por consiguiente la normalización por $1/\sigma^2$ da una medida del poder espectral relativo al ruido blanco.

Para determinar el nivel de significancia tanto para el análisis de Fourier como el espectro wavelet, es necesario definir inicialmente un espectro teórico adecuado. En general para las series temporales de variables climáticas los espectros teóricos más apropiados son aquellos asociados a procesos de ruido blanco (un espectro de Fourier plano) y el ruido rojo (mayor poder con menor frecuencia).

La transformada wavelet (1.20) es una serie de filtros de banda de series temporales. Si la serie temporal puede ser modelada como un proceso autoregresivo de lag-1, la distribución del poder espectral de Fourier es

$$\frac{N|\hat{X}_k|^2}{\sigma^2} \Rightarrow \frac{1}{2} P_k \chi_2^2 \quad (1.23)$$

para cada índice de frecuencia k y \Rightarrow indica “se distribuye como”, mientras que P_k se define como

$$P_k = \frac{1 - \alpha^2}{1 + \alpha^2 - 2\alpha \cos(2\pi_k / N)} \quad (1.24)$$

donde α se asume como el coeficiente de autocorrelación para el lag 1. La correspondiente distribución del poder espectral wavelet local es

$$\frac{|W_n(s)|^2}{\sigma^2} \Rightarrow \frac{1}{2} P_k \chi_2^2 \quad (1.25)$$

para cada tiempo n y escala s . Luego de definir el apropiado espectro teórico y elegir el nivel de confianza para una distribución, como por ejemplo 95%, es posible recalculando (1.20) para cada escala y construir un intervalo de confianza al 95%.

El análisis wavelet se puede utilizar para examinar fluctuaciones del poder espectral sobre un rango de escalas (bandas). Para esto es posible definir el poder espectral promediado en escala como la suma pesada del poder espectral wavelet entre las escalas s_1 a s_2 ,

$$\overline{W}_n^2 = \frac{\Delta_j \Delta t}{c \Delta} \sum_{j=j_1}^{j_2} \frac{|W_n(s_j)|^2}{s_j} \quad (1.26)$$

como resultado de (1.26) se obtiene una serie temporal que representa la varianza media para el ancho de banda analizado. Por esto, el poder espectral promediado en escala, puede ser utilizado para examinar la modulación de una serie sobre otra, o la modulación de una frecuencia por otra en la misma serie temporal.

1.5.5 Métodos de Clasificación

Para que un agrupamiento de objetos sea considerado como una clasificación se deben cumplir tres axiomas (Williams y Dale, 1965)

- a) En cada clase de más de un objeto debe existir, para cada objeto de la clase, otro distinto que comparta con él, como mínimo un atributo.
- b) El ser miembro de una clase no es en sí un atributo
- c) Cada objeto de cualquier clase debe diferir, al menos en un atributo de cada objeto, de otra clase.

Estos axiomas son suficientes para estructurar una clasificación, pero no necesariamente una que sea útil, ya que la clasificación de un grupo de objetos no es única. Así, el problema no es clasificar, sino lo que presenta mayores dificultades es encontrar razones para elegir una solución entre la variedad de posibilidades.

1.5.6 Análisis de Cluster.

En este tipo de análisis, se dispone de los valores de p variables X explicativas, para N objetos, y el objetivo es agruparlos en K grupos ($K < N$), de tal manera que los individuos que pertenecen a un grupo se parezcan lo más posible entre sí con respecto a esas variables, y a su vez difieran lo máximo posible de los individuos de otros grupos. Este planteamiento es completamente diferente de la metodología estadística habitual ya que aquí no hay una hipótesis previa.

Existen diferentes procedimientos para construir los grupos, y diferentes formas de determinar cómo se mide la similitud. Para ello se introduce el concepto de distancia entre las observaciones, que a su vez también viene determinado por el tipo de variables que se analizan, ya sean éstas cuantitativas como por ejemplo la temperatura, cualitativas ordinales en las que al resultado se le puede asignar un número cuyo orden tiene sentido, pero no la diferencia entre dos valores, y cualitativas nominales que corresponden a una etiqueta y donde la similitud se determina como simple coincidencia de valores.

1.5.7 P.A.M. (Partitioning Around Medoids)

El algoritmo P.A.M. (Kaufman and Rousseeuw 1990) se basa en la búsqueda de k objetos representativos (medoids) a lo largo del conjunto de datos. Estas observaciones representan la estructura de los datos. Un medoid se define como el objeto de grupo, cuya desemejanza media a todos los objetos del grupo es mínimo. Luego de encontrar el grupo de k centros, se construyen k grupos (clusters) al asignar cada observación al centro más cercano. Esto es, el objeto i , es asignado al cluster v_i , cuando el medoid mv_i es el más cercano con respecto a cualquier otro medoid m_w .

$$d(i, mv_i) \leq d(i, m_w) \text{ para todo } w = 1, \dots, k \quad (1.28)$$

Los k objetos representativos deben minimizar la función objetiva, la cual es la suma de las desemejanzas del medoid más cercano:

$$\text{Función objetiva} = \sum d(i, mv_i) \quad (1.29)$$

Diámetro del Cluster

El diámetro del cluster C se define como el valor de la mayor desemejanza perteneciente a este grupo.

$$\mathbf{Diámetro}(C) = \max d_{ij}, i, j \in C \quad (1.30)$$

Separación del Cluster

La separación del grupo C se define como la desemejanza más pequeña entre dos objetos; uno perteneciente al cluster C y el otro pertenece a cualquier cluster distinto de C.

$$\mathbf{Separación}(C) = \min d_{lh}, l \in C, h \notin C \quad (1.31)$$

Distancia media a un medoid

Si j es el medoid del cluster C, la distancia media de todos los objetos de C a j , se calcula:

$$\mathbf{Distancia\ media}_j = \frac{\sum_{i \in C} d_{ij}}{N_j} \quad (1.32)$$

Distancia máxima al medoid

Si j es el medoid del cluster C, la máxima distancia de todos los objetos de C a j , será:

$$\mathbf{Distancia\ máxima}_j = \max d_{ij}, i \in C \quad (1.33)$$

Cada cluster es representado por una silueta, demostrando qué objetos definen al grupo y qué objetos se encuentran simplemente en una posición intermedia.

Las siluetas se construyen considerando a cualquier objeto i del conjunto de datos, y A denota el cluster donde es asignado i , entonces se define:

$$\mathbf{a(i)} = \text{desemejanza media de } i \text{ con respecto a todos los objetos de } A \quad (1.34)$$

Ahora, considerando cualquier cluster C distinto de A, será

$$\mathbf{d(i, C)} = \text{desemejanza media de } i \text{ con respecto a todos los objetos de } A \quad (1.35)$$

Calculando $d(i, C)$ para todos los clusters $C \neq A$, se seleccionan los valores mínimos:

$$b = \min d(i, C), \quad C \neq A \quad (1.36)$$

Ahora sea B el cluster donde se alcanza el mínimo, $d(i, B) = b(i)$, así se define el valor $s(i)$ como:

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (1.37)$$

De aquí se desprende que $s(i)$ toma valores entre -1 y +1. Si el valor de $s(i)=1$, está asociado a un cluster apropiado, el segundo mejor cluster B, no se encuentra tan cerca como lo está el cluster A. Si $s(i)=0$, se trata de un caso intermedio, donde el valor i , puede pertenecer tanto al grupo A como al B. Luego, cuando $s(i)=-1$ el objeto está mal clasificado, es decir, debería pertenecer a otro grupo.

Finalmente el ancho medio de la silueta se puede utilizar para definir si la cantidad de clusters elegidos es correcta. Para esto se define:

$$SC = \max s(k) \quad (1.38)$$

Donde el máximo se toma sobre los k grupos. Este coeficiente es una medida adimensional de la medida de los clusters. Si este coeficiente toma valores mayores a 0.71, se puede considerar hallada una sólida estructura, si SC toma valores entre 0.51 y 0.70, se puede definir como una estructura razonable, mientras que si SC es menor a 0.50, la estructura es débil y podría ser artificial.

1.5.8 K-MEANS

El algoritmo de agrupación K means fue desarrollado por MacQueen (1967) y una completa descripción de esta metodología se puede encontrar en Hartigan and Wong (1979). Este algoritmo al igual que P.A.M. permite particionar un conjunto de N observaciones en K grupos S_j donde cada subgrupo contiene N_j datos. Para obtener estos grupos se utiliza el criterio tal que la suma (1.39) sea mínima

$$J = \sum_{j=1}^K \sum_{n \in S_j} |x_n - \mu_j|^2 \quad (1.39)$$

donde X_n es el vector que representa la ene-ésima observación y μ_j es el centroide geométrico de los datos en el grupo S_j .

El método comienza a iterar a partir de un conjunto inicial de K medias (m_1, \dots, m_k) que se especifican aleatoriamente. A partir de estas condiciones iniciales el algoritmo procede alternadamente entre dos pasos. La etapa de asignación, asigna a cada observación al grupo con media más cercana.

$$S_i^{(t)} = \{x_j : \|x_j - m_i^{(t)}\| \leq \|x_j - m_{i^*}^{(t)}\| \forall i^* = 1, \dots, k\} \quad (1.40)$$

Luego la etapa de actualización donde se calculan nuevamente las medias de cada grupo donde se determinan los centroides de cada grupo.

$$m_i^{(t+1)} = \frac{1}{|S_i^{(t)}|} \sum_{x_j \in S_i^{(t)}} x_j \quad (1.41)$$

Se iteran estos algoritmos hasta que no existan cambios significativos en los valores de los centroides.

1.5.9 Identificación del número de clusters

Una aproximación comúnmente utilizada para determinar el número de clústeres óptimos es aplicar algún criterio sobre la bondad del ajuste entre un conjunto de datos y el resultado de la clasificación. En este trabajo se utiliza el criterio propuesto por Hartigan (1975). El índice de Hartigan examina los cambios relativos del ajuste como cambios de las propiedades de los grupos.

Si se asume que el conjunto de datos contiene N muestras de la variable X_i con $i=1, \dots, N$, el resultado de la clasificación produce k clústeres, el ajuste de la clasificación se puede expresar como el error medio cuadrado entre todas las muestras.

$$err(k) = \sum_{i=1}^k \sum_{j=1}^N d^2(X_j, X_{ci}) \quad (1.42)$$

Donde d es la distancia entre la muestra X_j y el centro X_{ci} . El Índice de Hartigan $H(k)$ para la partición k , se expresa como;

$$H(k) = (n - k - 1) \frac{err(k) - err(k + 1)}{err(k)} \quad (1.43)$$

Dado que $H(k)$ es monótonamente decreciente cuando k aumenta, la relación es una medida relativa de la reducción del error cuadrado cuando el numero de clústeres aumenta desde k hasta $k+1$. El optimo numero de k es aquel que maximiza el valor de $H(k)$.

1.5.10 Análisis de Componentes principales

El análisis de componentes principales (ACP), desarrollado por Pearson en 1901, es una herramienta de clasificación que transforma un número de variables posiblemente correlacionadas en un número menor de variables no correlacionadas denominadas componentes principales. La primera componente describe la mayor variabilidad de la información analizada, mientras que las siguientes componentes describen la variabilidad remanente.

El Análisis de componentes principales es una transformación lineal ortogonal que transforma un conjunto de datos X en un nuevo sistema de coordenadas. Por esto, sea X una matriz de p dimensiones, conformada por p variables con N observaciones.

$$X = \begin{bmatrix} x_{11} & x_{12} & x_{13} & \cdot & \cdot & x_{1p} \\ x_{21} & x_{22} & x_{23} & \cdot & \cdot & x_{2p} \\ x_{31} & x_{32} & \cdot & \cdot & \cdot & x_{3p} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ x_{N1} & x_{N2} & x_{N3} & \cdot & \cdot & x_{Np} \end{bmatrix} \quad (1.44)$$

Mediante Componentes Principales (ACP), el conjunto total de p variables podría ser reducido a un nuevo conjunto enteramente independiente de nuevas variables expresada en un matriz resultante Z de orden k -dimensional.

$$Z = \begin{bmatrix} z_{11} & z_{12} & z_{13} & \cdot & \cdot & z_{1p} \\ z_{21} & z_{22} & z_{23} & \cdot & \cdot & z_{2p} \\ z_{31} & z_{32} & \cdot & \cdot & \cdot & z_{3p} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ z_{N1} & z_{N2} & z_{N3} & \cdot & \cdot & z_{Np} \end{bmatrix} \quad (1.45)$$

Habiendo definido \mathbf{X} y \mathbf{Z} , con p variables (originales y transformadas) y N observaciones, consideremos adicionalmente la matriz de covarianza Σ de la matriz \mathbf{X} ; entonces ACP permite calcular mediante la matriz Σ un nuevo conjunto de p variables no correlacionadas (z) tal que ellas sean combinación lineal de las variables originales. De este modo, para cualquier observación i en \mathbf{X} dado por $[x_1 \ x_2 \ x_3 \ \dots \ x_p]$, existe una función lineal $\mathbf{Z} = \mathbf{a}'\mathbf{x}$, para todo $i=1, \dots, N$. Es decir,

$$z = a_{i1} x_1 + a_{i2} x_2 + a_{i3} x_3 + \dots + a_{ip} x_p, \quad j=1, \dots, P, \quad i=1, \dots, N \quad (1.46)$$

A partir de esto, el objetivo es encontrar los componentes principales \mathbf{a}_j tal que $\mathbf{a}'_j \Sigma \mathbf{a}_j$ es un máximo sujeto a que $\mathbf{a}'_j \mathbf{a}_j = 1$, donde $j=1, \dots, P$. Usando Lagrange para el j -ésimo componente, se tiene:

$$L = \mathbf{a}'_j \Sigma \mathbf{a}_j - \lambda_j (\mathbf{a}'_j \mathbf{a}_j - 1) \quad (1.47)$$

λ_j es el multiplicador y la parcial con respecto al componente es

$$\frac{\partial L}{\partial a_j} = 2 \sum a_j - 2 \lambda_j a_j \quad (1.48)$$

Igualando a cero la expresión anterior se calculan los valores de λ_j mediante $(\Sigma - \lambda_j I) \mathbf{a}_j = 0$, donde $|\Sigma - \lambda_j I| = 0$ para que $\mathbf{a}_j \neq 0$. Existen p raíces para el polinomio. Estas raíces son los autovalores de Σ y son $\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_p$. Cada valor de λ_j permite el cálculo de su correspondiente autovector \mathbf{a}_j mediante $(\Sigma - \lambda_j I) \mathbf{a}_j = 0$.

De ahí, el primer autovector \mathbf{a}_1 le corresponde el primer autovalor λ_1 , el cual se obtiene mediante $(\Sigma - \lambda_1 I) \mathbf{a}_1 = 0$ y la condición de ortonormalidad $\mathbf{a}'_1 \mathbf{a}_1 = 1$; a su vez \mathbf{a}_1 es el autovector correspondiente a la varianza más grande de Σ , $\text{var}(\mathbf{a}'_1 \mathbf{x}) = \mathbf{a}'_1 \Sigma \mathbf{a}_1 = \lambda_1$, y

$z_1 = a_1'x$. El segundo autovector a_2 es la segunda varianza más grande Σ y así sucesivamente.

En general, *El j -ésimo* a_j es ortonormal a $a_j, j=1$ es ortogonal al resto de los autovectores previamente calculados. Así mismo, las varianzas para los p autovectores es decreciente tal que $V(z_1) > V(z_2) > \dots > V(z_p)$. Finalmente, los autovectores son los componentes principales y los autovalores la varianza de las nuevas variables.

CAPITULO 2

ESTIMACION Y FILTROS DE LA ONDA ANUAL

2.1 Variación estacional en escala diaria de la temperatura y precipitación

En general para gran cantidad de métodos estadísticos relacionados con la construcción de modelos, se asume que las observaciones varían de forma independiente. Sin embargo para muchas variables del sistema climático existe dependencia entre observaciones y la naturaleza de esta dependencia tiene interés por si misma (Box and Jenkins, 1970).

Por esto la habilidad de comprender las relaciones dinámicas entre variables y sintetizarlas en forma de series temporales es necesario efectuar un control óptimo. Así mismo el compromiso de obtener el mejor pronóstico numérico es necesario, ya que se debe estimar el riesgo asociado con las decisiones basadas en éste pronóstico.

En términos generales una función de transferencia $F(t)$ se define como la relación $x_t = F(t)x_{t+1} + \varepsilon$ donde x_t representa el valor de la serie para el tiempo t y ε el error (Jenkins and Watts, 1968). En general los métodos utilizados para estimar la función de transferencia basada en perturbaciones determinísticas como la entrada a través cambios sinusoidales, por ejemplo no han sido siempre exitosos. Esto es porque para perturbaciones de magnitud relevante la respuesta del sistema está enmascarada por perturbaciones incontrolables referidas como ruido (Box and Jenkins, 1970).

Como en la mayoría de las variables climáticas la función de entrada es principalmente la onda anual astronómica para una latitud dada y a través de la función de transferencia asociada a éste proceso se obtiene la onda anual de temperatura. En general los procesos transientes de alta frecuencia pueden ser considerados como ruido respecto de la onda anual. Sin embargo, existen algunos procesos que por su recurrencia y magnitud afectan la función de transferencia, estas fluctuaciones de origen estadístico se pueden definir como ruido climático (Leith, 1973, 1978).

La fluctuación anual de la temperatura es una de las oscilaciones periódicas más conocidas en climatología, Köppen (1948), siendo ésta una respuesta directa de la radiación solar incidente, Selliers (1965). Su magnitud es extremadamente grande, siendo comparable a la del ciclo glacial-interglacial. Si bien, aunque se observan tendencias en la fase y amplitud de la onda anual, las causas y el significado de estos cambios siguen siendo poco

conocidos, en parte porque se carece de una comprensión de la variabilidad natural (Stine et al, 2009).

Sin embargo, las principales causas de los cambios en la amplitud de la onda anual esta dada por cambios en la dinámica de los efectos transitorios y no por cambios en la onda astronómica. Por esto es posible considerar un sistema de referencia fijo a partir del cual se pueda estimar la magnitud de las anomalías En particular las series de temperatura están dominadas por éste efecto determinístico (explica entre el 70 y el 90 % de la varianza total de la serie), es decir es un efecto que no varía año tras año (Brooks y Carruthers (1953) y Strauss (1983)).

Se desea filtrar la onda anual y definirla como nuevo sistema de referencia para determinar los procesos transitorios o de baja frecuencia que pueden recurrir en estas series. Para esto es necesario diseñar un filtro o función de transferencia que introduzca el menor ruido posible ya que el análisis en escala diaria puede ser oscurecido por esta elección. En las secciones siguientes se propone una discusión sobre la robustez y estabilidad de los métodos más comúnmente utilizados para filtrar la onda anual.

2.2 Modelos de descomposición de series temporales

La descomposición de series temporales permite identificar importantes propiedades de la información contenida en éstas a través un diagnóstico objetivo. Así mismo estos procedimientos pueden ayudar a monitorear las series con el tiempo, especialmente cuando es necesaria la toma de decisión.

Como primer aproximación a la descomposición se asume que las series de tiempo pueden ser descompuestas en tres componentes básicas:

- a) tendencias
- b) estacionalidad
- c) las variaciones irregulares o efectos transientes que permanecen en las series una vez removidos la tendencia y el efecto estacional.

Dado que el presente trabajo de tesis está centrado en el estudio de las fluctuaciones y procesos transientes que dominan a la temperatura en escala diaria, es necesario definir un

sistema de referencia a partir del cual efectuar el cálculo de las anomalías. Surge esto como prioridad inicial del análisis ya que la elección defectuosa del filtro puede inducir a la generación de ruido o periodicidades espurias.

La estacionalidad es la porción de la variación debida a factores que recurren sistemáticamente una o más veces al año. Un efecto estacional es razonablemente estable con respecto al tiempo en dirección y magnitud. Respecto a la temperatura el efecto estacional está regido principalmente por la onda anual astronómica, a partir de la cual se desea analizar los apartamientos de las condiciones normales producidos por factores tanto internos como externos al sistema climático.

Estos efectos irregulares son evidencia de las fluctuaciones de corto plazo en las series que no son sistemáticas (aunque no necesariamente debido a factores aleatorios) y contienen baja predictabilidad. Sin embargo, los procesos asociados a estos fenómenos transientes contienen gran cantidad de información y pueden ser utilizados para mejorar la calidad de las predicciones.

Conociendo estos elementos, es posible definir aquel modelo de representación que muestre una componente estacional más estable, lo cual es lo más apropiado para ajustar a las series. En general hay dos modelos de representación más comúnmente usados, el aditivo y el multiplicativo (Chatfield, 1989).

2.2.1 Modelo de descomposición aditivo

El modelo de descomposición aditivo asume que las componentes de las series se comportan de manera independiente. Este modelo se utiliza si los efectos estacionales e irregulares son independientes, es decir el efecto de la onda anual no varía con el tiempo.

Matemáticamente, la serie original x_t , en el tiempo t , se considera como la suma de las tres componentes: la tendencia T_t , la estacional S_t , y la irregular I_t .

$$x_t = T_t + S_t + I_t \quad (2.1)$$

En el modelo aditivo, cada componente tiene las mismas dimensiones que la serie original. La serie ajustada por estacionalidad se puede expresar como

$$x'_t = x_t - S_t = T_t + I_t \quad (2.2)$$

2.2.2 Modelo de descomposición multiplicativo

En éste modelo las variaciones irregulares no son independientes de la onda anual, es decir la magnitud de las anomalías depende directamente de la época del año. La serie x_t , en el tiempo t , es considerada como el producto de las componentes estacional S_t , la tendencia T_t e irregular I_t

$$x_t = T_t \times S_t \times I_t \quad (2.3)$$

En el modelo multiplicativo la tendencia tiene las mismas dimensiones que la serie original, mientras que las componentes estacional e irregular son factores adimensionales centrados alrededor de uno.

$$x'_t = x_t / S_t = T_t \times I_t \quad (2.4)$$

Los modelos para determinar cada una de las componentes, generalmente utilizan simultáneamente los filtros de Kalman o técnicas relacionadas. En Harvey (1990) se muestra un detallado análisis de los métodos. En líneas generales a cada componente se le asigna su propio modelo determinado por sus características espectrales. Uno de los métodos más utilizados para descomponer series temporales es el “Classical Seasonal Decomposition” (CSD). Esta técnica es descripta y discutida en detalle en Makridakis and Wheelwright (1989) y Makridakis, Wheelwright, and McGee (1998).

A modo de prueba se calcularon las descomposiciones de las series de temperatura mínima en San Miguel De Tucumán y precipitación en O.C.B.A. según los modelos aditivo y multiplicativo utilizando el método CSD. Si bien se muestra el análisis para el período 1998-2005, los valores estacionales fueron estimados a partir del período completo que se dispone de información diaria (1891-2005), no considerar toda la información disponible o si ésta es escasa puede inducir a errores en la estimación de la estacionalidad debido a que efectos transitorios pueden ser considerados como parte de la onda anual y por consiguiente su dependencia con ésta será mayor. Este tópico se discutirá sección en las siguientes

secciones, en especial la influencia del período en la estabilidad de la estimación de la onda anual.

En las figuras 2.1 y 2.2 se muestran las componentes S_t , T_t e I_t según los dos métodos. Si bien las dos estimaciones muestran el mismo comportamiento de la onda estacional, se observan diferencias significativas en la componente irregular de la serie. Los residuos para el método aditivo no muestran una estacionalidad definida con una magnitud similar durante todo el año. Esto evidencia que la mayor parte de los efectos que dominan las series son lineales.

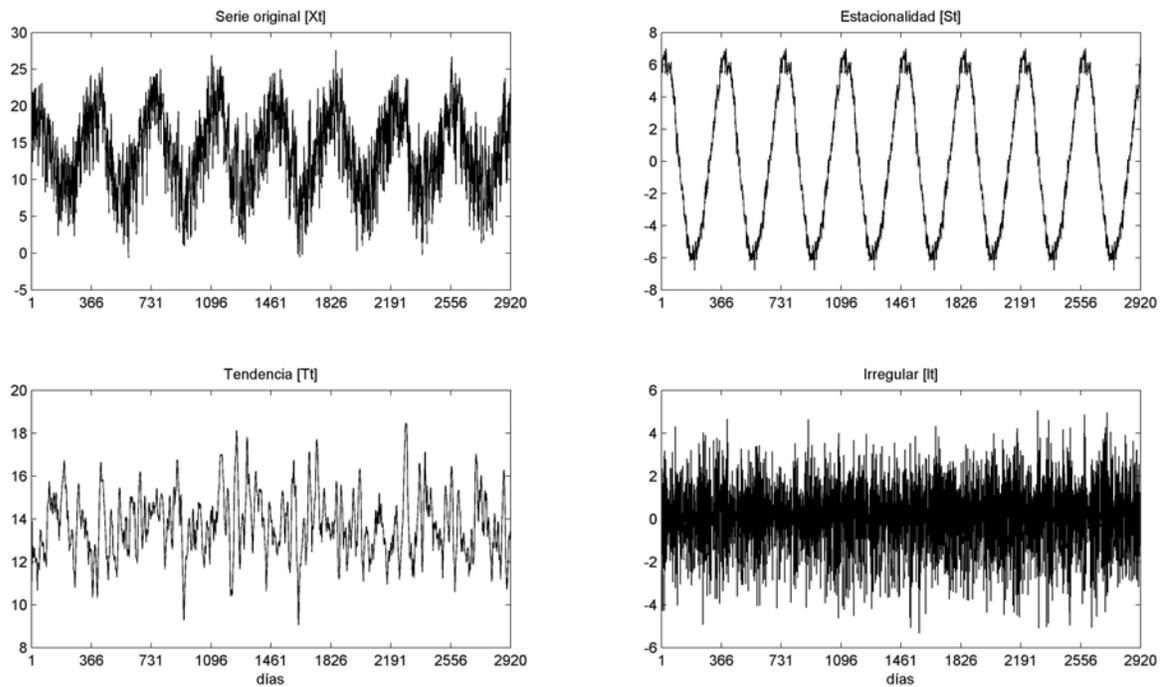


Figura 2.1. Descomposición aditiva para la temperatura mínima diaria en OCBA (1998-2005), basado en el período 1910-2005

Para el método multiplicativo se observa una mayor amplitud de las irregularidades en el invierno, principalmente dominado por irrupciones frías. Así mismo la menor amplitud de los residuos, principalmente en las estaciones de transición evidencia una mayor dependencia del término no lineal en estas épocas del año. Esto concuerda con lo encontrado en Minetti y Vargas (1997) donde muestran la existencia de una importante

interacción entre la onda estacional y las perturbaciones debido a una lenta interacción entre las condiciones de borde y la atmósfera.

Si el mismo análisis se realiza para variables discretas, como la precipitación, es posible advertir la dificultad de separar el efecto estacional del irregular. En la figura 2.3 se muestra la descomposición aditiva mediante CSD para la precipitación diaria en O.C.B.A. El método multiplicativo no puede ser utilizado cuando las series contienen ceros. Es posible

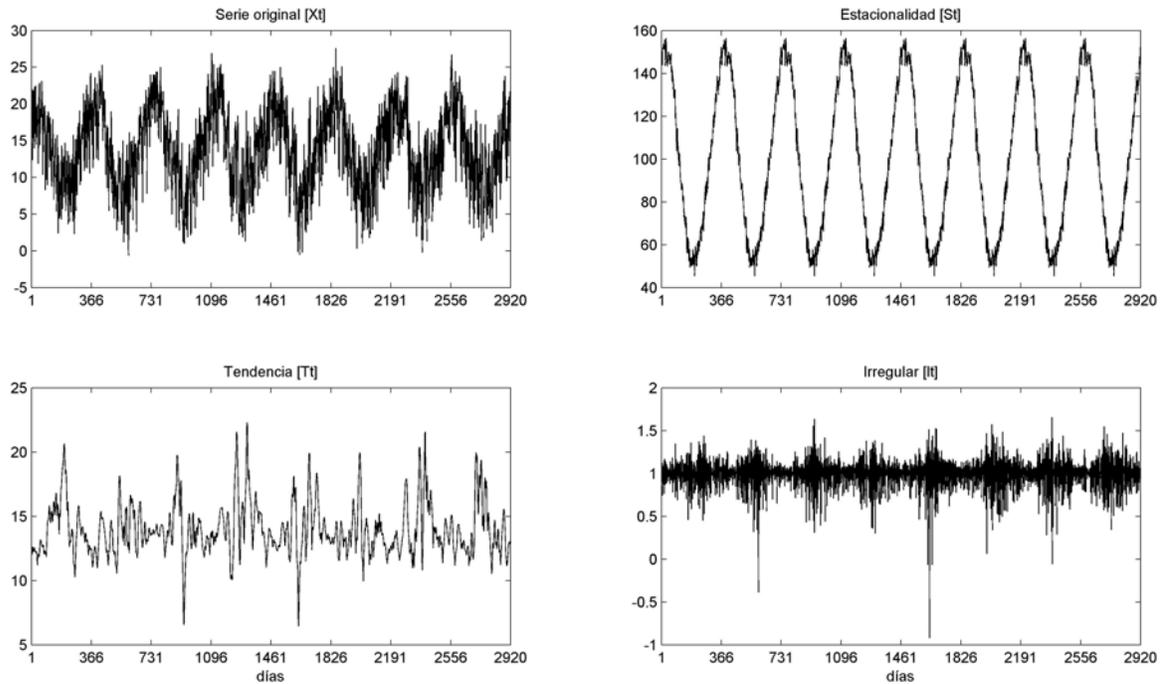


Figura 2.2. Descomposición multiplicativa para la temperatura mínima diaria en OCBA (1998-2005), basado en el período 1910-2005.

ajustar a estas series un modelo pseudo aditivo que combina propiedades de las relaciones aditivas y multiplicativas. Por las características discretas y sesgadas de la precipitación a escala diaria el término estacional muestra mayor ruido que la estimación de la onda anual para la temperatura. El efecto aleatorio en la ocurrencia de valores de precipitación extremos rige la distribución de los términos irregulares, con una mayor dispersión en las estaciones de transición y el verano. En otras palabras la precipitación es una variable altamente irregular respecto de su onda anual.

En una serie altamente irregular, los residuos pueden dominar causando que el efecto estacional sea difícil de identificar o estimar. Este fenómeno es más marcado cuando la variable se evalúa sobre pasos de tiempo cercanos a la variabilidad de alta frecuencia de las series, en particular en las series climáticas, puede ser la escala horaria o diaria.

Para determinar cuan irregular es una variable es útil comparar la relación existente entre la componente estacional (S_t) y la irregular (I_t). En líneas generales se puede definir que a mayor dispersión de I_t alrededor de S_t más irregular es la serie y se encuentra menos

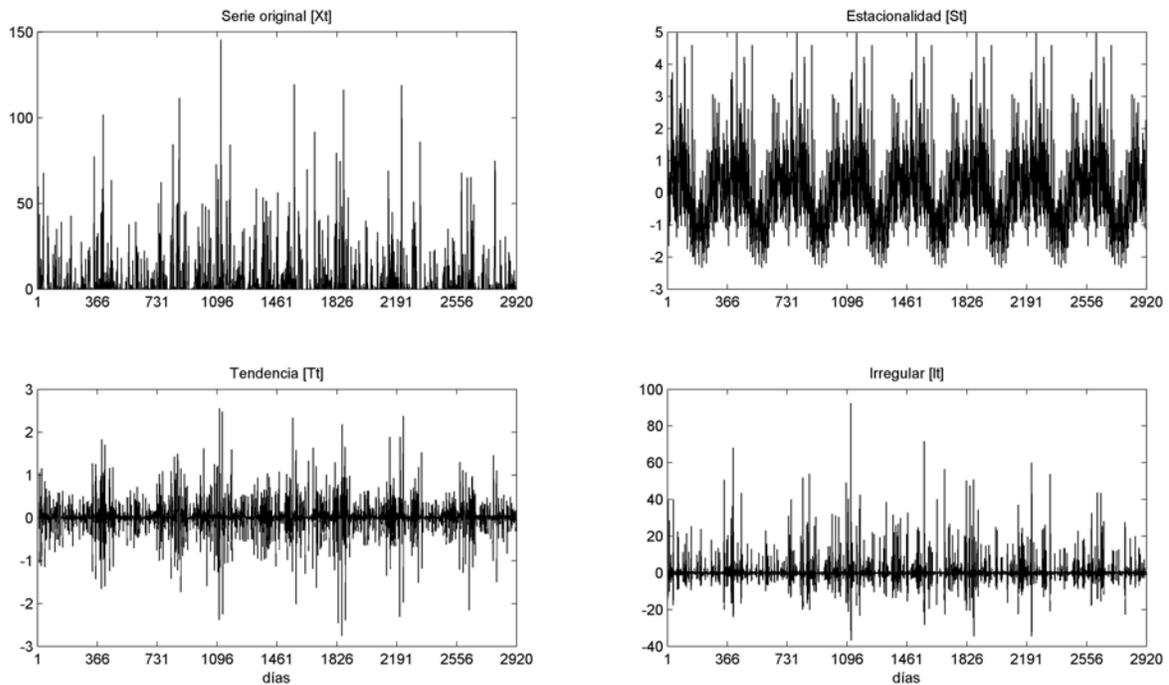


Figura 2.3. Descomposición aditiva para la precipitación diaria en OCBA (1998-2005), basado en el período 1910-2005.

condicionada por la onda anual. En la figura 2.4 se muestran los factores S_t e I_t para la temperatura y precipitación en el período 1998-2005.

La temperatura muestra un comportamiento altamente regular respecto de la onda anual para los dos modelos de descomposición. Sin embargo existe una mayor dispersión en invierno para la estimación según el método multiplicativo, principalmente respecto a las irrupciones frías intensas y un mejor ajuste a este modelo en las estaciones de transición.

En el caso de la precipitación se tiene una alta dispersión con valores que superan cuatro o cinco veces a los valores estacionales. Esta es una serie irregular dominada por el efecto de los extremos, es decir la influencias de los efectos transientes de alta frecuencia puede implicar que las anomalías difieran marcadamente de la onda anual.

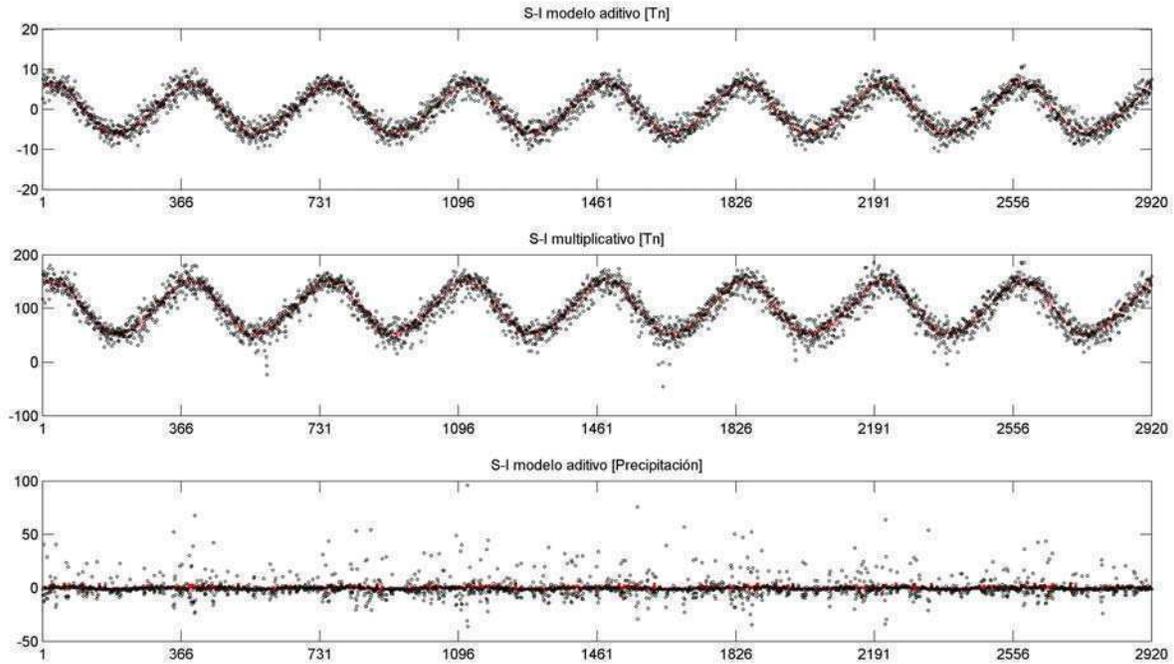


Figura 2.4. Relación entre la estacionalidad (líneas rojas) e irregularidad (puntos) para las series de temperatura mínima y precipitación en OCBA (1998-2005).

2.3 Métodos basados en filtros

2.3.1 Estimación de la onda anual mediante los promedios diarios

Para poder caracterizar la onda anual a partir de los promedios diarios es necesario definir parámetros que sinteticen el comportamiento de ésta oscilación. El parámetro más común que define las características térmicas de un día en particular es el valor medio de éste, calculado como la media aritmética. Sin embargo, para obtener una buena estimación de éste parámetro, el valor de ésta debe ser estable. Por éste motivo se discute a continuación sobre la estimación robusta de los modelos de posición.

¿Por que analizar la eficiencia de un estimador? Para solventar las dificultades asociadas a la inestabilidad que presentan los estimadores, se plantea el uso de estimadores dentro del campo de la Estadística Robusta. Esta rama de la Estadística se centra en el desarrollo y análisis de estimadores que son estables (robustos) frente a cambios en las distribuciones supuestas. Por esto si la variable analizada presenta cambios que pueden estar debidos tanto a efectos naturales como antropogénicos que pueden afectar su distribución, los efectos de ésta inestabilidad se pueden reflejar en la estimación de otros parámetros derivados de éstos momentos.

Supongamos sea $F = \phi$, la función de distribución $N(0,1)$, entonces las x_i tienen distribución $N(\mu, \sigma^2)$. Por lo tanto, un estimador óptimo de μ es

$$\bar{x} = \sum_i^n \frac{x_i}{n} \quad (2.5)$$

Es importante señalar que para que \bar{x} tenga ésta propiedad, la distribución de los x_i debe ser exactamente $N(0,1)$. Sin embargo, en la mayoría de las aplicaciones prácticas a lo sumo se puede asegurar que los errores de medición tienen distribución aproximadamente normal. Por lo tanto cabe preguntarse cual será el comportamiento del estimador \bar{x} en este caso.

Esta extrema sensibilidad de \bar{x} a una contaminación con una proporción pequeña de outliers o extremos también puede verse de la siguiente forma. Supongamos que se tiene una muestra x_1, \dots, x_n y se agrega una observación x_{n+1} . Si esta observación es un outlier, su influencia en \bar{x} puede ser ilimitada. En efecto sean \bar{x}_n y \bar{x}_{n+1} el promedio basado en n y $n+1$ observaciones respectivamente. Luego se tiene

$$\bar{x}_{n+1} = \frac{n}{n+1} \bar{x}_n + \frac{1}{n+1} x_{n+1} = \bar{x}_n + \frac{1}{n+1} (x_{n+1} - \bar{x}_n) \quad (2.6)$$

y por lo tanto \bar{x}_{n+1} puede tomar valores tan altos (o tan bajos) como se quiera con tal de tomar x_{n+1} suficientemente lejos de \bar{x}_n . Por lo tanto cabe preguntarse cual será el comportamiento del estimador \bar{x} en nuestro caso. Como primer análisis y dado que la

variable analizada es la temperatura se decide analizar la robustez del estimador sobre las series de temperaturas de S. M. de Tucumán.

Una de las formas más simples de estimar el parámetro de posición es hacer la media aritmética menos sensitiva a los outliers o extremos, para esto es posible ajustar o eliminar una porción de datos de cada cola de la distribución y computar la media de los valores remanentes. Esta media ajustada pertenece a una familia de estimadores que puede ser indexada por α , valor que representa la fracción de observaciones eliminadas en cada cola de la distribución de la muestra. Formalmente, si $x_1 \leq x_2 \leq \dots \leq x_n$, es la serie ordenada de una muestra de datos aleatoria, entonces la media α -ajustada tiene la forma;

$$\bar{x}_\alpha = \frac{1}{n(1-2\alpha)} \left\{ \sum_{i=k+2}^{n-k-1} x_i + (1+k-n\alpha)[x_{k+1} + x_{n-k}] \right\} \quad (2.7)$$

si $k+2 \leq n-k-1$. Si ocurre lo contrario,

$$\bar{x} = \frac{1}{2} [x_{k+1} + x_{n-k}] \quad (2.8)$$

Donde k es el mayor entero menor o igual que $n\alpha$ con $0 < \alpha < 0.5$

Las medias ajustadas incluyen casos especiales como la media aritmética ($\alpha=0$), la “midmean” ($\alpha=0.25$) y la mediana ($\alpha=0.5$). la elección de α depende de cada distribución, donde la no-normalidad de los datos y el nivel de protección que se desea sobre los outliers o extremos juegan el rol más importante. Los valores más frecuentes utilizados α para incluyen a 0, 0.05, 0.1, 0.25 y 0.5.

Por ejemplo, si aplicamos el ajuste con $\alpha=0.25$ a un conjunto de datos con $\{x_1, x_2, \dots, x_8\} = \{1, 2, 3, 4, 6, 7, 8, 50\}$ resulta en

$$\bar{x}_{0.25} = \frac{1}{8(1-0.5)} \{x_4 + x_5 + (1+2-2)[x_3 + x_6]\} = \frac{1}{4} \sum_{i=3}^6 x_i = 0.25(3+4+6+7) = 5$$

Es de suponer que la estimación de los promedios varíe con la cantidad de datos o años con que se calculan estos, con lo cual la elección de la cantidad de información es un elemento importante para tener en cuenta como filtro de los efectos transientes. Con esto, es posible

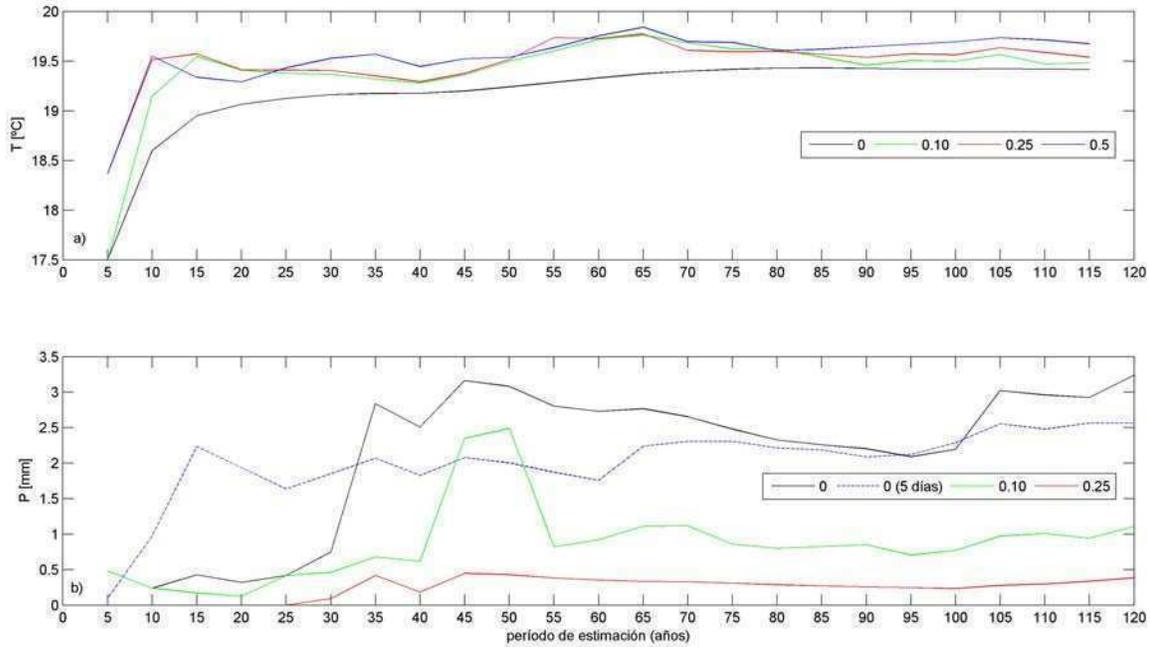


Figura 2.5. Estimación de la temperatura mínima y precipitación media del primero de enero en OCBA para períodos entre 5 y 120 años, según las medias ajustadas por $\alpha=0$, $\alpha=0.10$, $\alpha=0.25$ y $\alpha=0.5$.

aplicar ésta estimación (suponiendo $\alpha=0, 0.1, 0.25$ y 0.5) para cada día del año sobre las series de temperatura y precipitación para períodos que varían entre 5 y 120 años. Como primera aproximación se muestran en la figura 2.5 los valores medios anuales de la temperatura mínima y precipitación del 1 de enero estimados según las ecuaciones (2.5) y (2.6).

Para la temperatura se observa que la estimación del valor medio comienza a estabilizarse a partir de 30-40 años de información. Se observan grandes diferencias entre las primeras estimaciones (períodos de 5 y 10 años) y las estimaciones con 30-40 años de datos. En particular, estas diferencias tienen una magnitud de casi 2 °C. Con esto se podría sugerir que una estimación de la onda anual con 40 años de datos es una buena aproximación a la onda anual astronómica. Sin embargo a partir de 80 años de datos se observa otra región de convergencia de las estimaciones con diferencias entre si de menos de 0.5 °C.

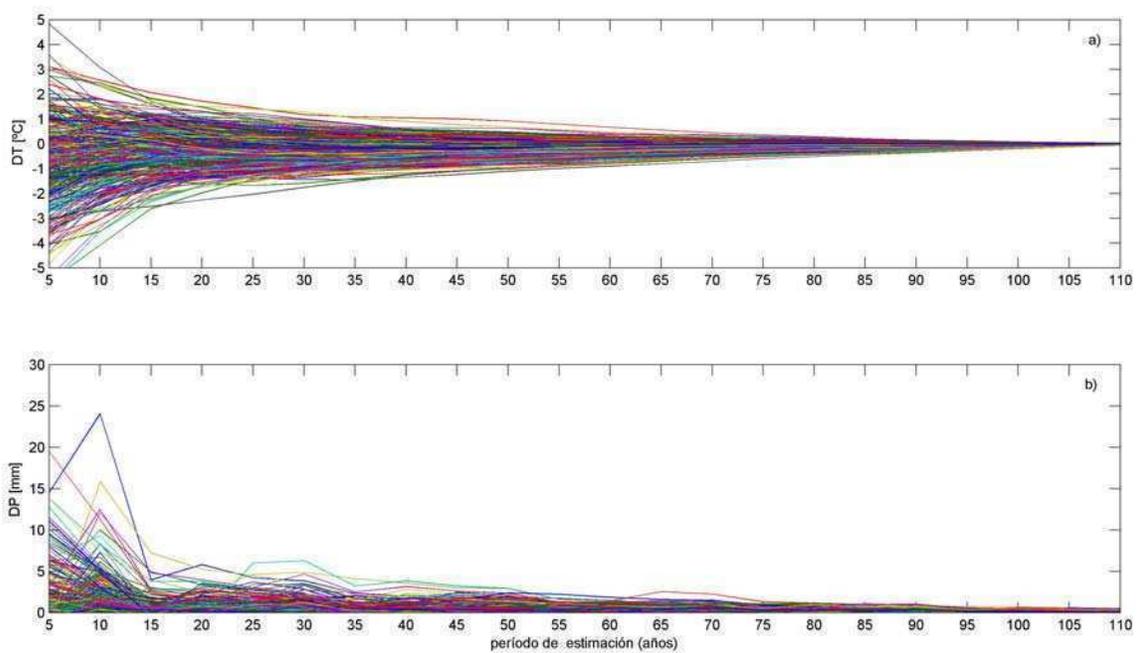


Figura 2.6. Errores en la estimación de cada día del año con periodos de distinta longitud par la temperatura mínima (a) y la precipitación (b).

En cuanto a las estimaciones sesgadas con $\alpha=0.25$ y $\alpha=0.5$ parecen converger más rápidamente (aproximadamente 20-30 años) a los valores estimados con mayor cantidad de datos, mientras que los estimadores con $\alpha=0$ y $\alpha=0.1$ muestran una mayor estabilidad con 40-50 años de información.

Las estimaciones para el 1° de enero en la precipitación (Figura 2.5b) muestran un comportamiento más heterogéneo. En este caso los valores son más similares para los períodos más cortos, mientras que a medida que suceden eventos con mayor precipitación los valores calculados para los distintos α se apartan significativamente. Si bien aparenta ser más estable las estimaciones con α altos, éstas están regidas en mayor medida por la presencia de ceros y en algunos casos se puede despreciar el efecto de los valores más altos de precipitación. Por esto una forma más estable de calcular los valores medios de precipitación para el día i , $i=1, \dots, 365$, es considerar ventanas de 3 o 5 días centradas en el día i . Este procedimiento permite filtrar los efectos de alguna manera aleatoria en la ocurrencia de la precipitación. En la figura 2.5b se comparan las estimaciones del promedio del primero de enero considerando solo este día y considerando una ventana de cinco días centrada en éste día. Se puede apreciar una menor dependencia de las estimaciones sobre ventanas de cinco días a la presencia de períodos húmedos (entre 30 y 40 años) y secos (90 años).

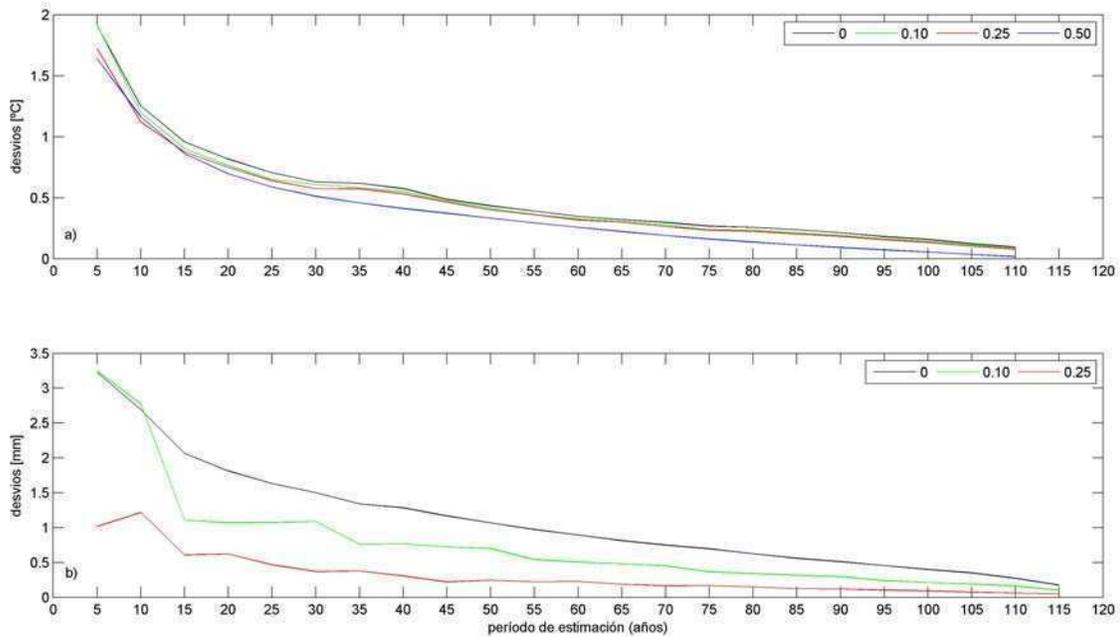


Figura 2.7. Desvíos de los residuos de la onda anual estimada de la temperatura mínima (a) y precipitación (b) con N años respecto de la onda anual estimada con el periodo completo.

Para generalizar los resultados se propone analizar la dispersión que surge al estimar la onda anual con n-años, $n=1, \dots, N$, comparando con la mejor estimación posible con el máximo N o sea con el período completo de información disponible. En la figura 2.6 se muestran las diferencias entre la onda anual ideal y aquellas estimadas para distintos períodos. Para la temperatura se observa que los errores se distribuyen uniformemente tanto a valores positivos como negativos, alcanzando valores entre 3-4 °C en los períodos más cortos. Para la precipitación se observan errores por exceso con magnitudes entre 4 y 10 mm hasta longitudes de períodos de 40 años.

En la figura 2.7-a se muestran los desvíos de los residuos de la estimación de la onda anual para la temperatura mínima en Tucumán y la precipitación diaria en OCBA tomando como período de referencia el total de 110 años. Considerando la temperatura, se tiene que las estimaciones de la onda anual para todos los α se comportan de manera similar, aunque la estimación con la mediana es la que converge más rápidamente a la mejor estimación. A partir de esta información es posible determinar el nivel de sensibilidad de la estimación en

función de la longitud del período. Si se tolera un error de 0.5 °C se requiere un período de 30 años para la mediana y de 40 años para los otros estimadores. Si la sensibilidad requerida es de 0.25 °C se necesitaran 60 años si estima a partir de la mediana, mientras que para los otros estimadores se requieren 70 años de información diaria.

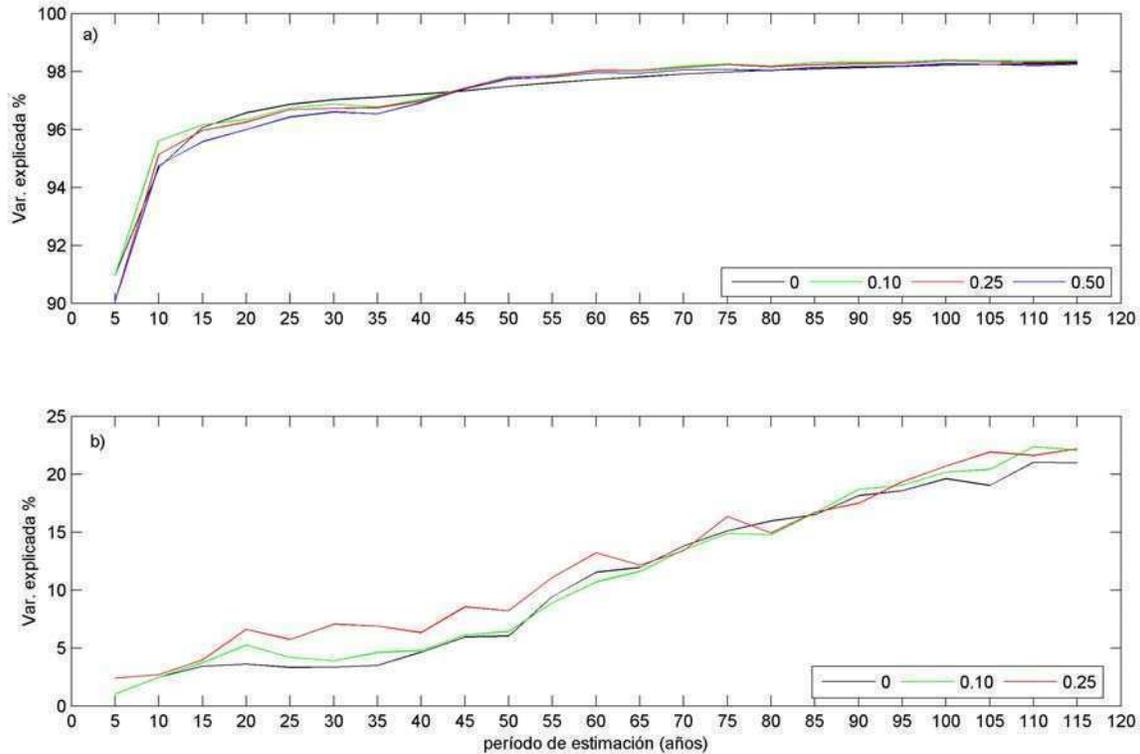


Figura 2.8. Varianza explicada por el primer armónico de la onda anual de temperatura mínima (a) y varianza explicada por los primeros tres armónicos de la onda anual de precipitación diaria (b) para estimaciones con distintas longitudes de registros.

Así mismo, es posible evaluar la mejora en la estimación de la onda anual en función del incremento en el período de datos a partir del cálculo de la varianza explicada por la onda anual respecto de la variación total. En la figura 2.8-a se muestra la varianza explicada por el primer armónico sobre la temperatura mínima. Dado el alto grado determinístico de la onda astronómica se observa que para el período de menor longitud (cinco años), ésta ya explica cerca del 90 %, a pesar de la presencia de efectos transitorios. A pesar de esto se

observa un crecimiento de la varianza explicada por la onda anual, estabilizándose en valores cercanos al 98 % con períodos de 50-60 años.

La precipitación diaria evidencia otro comportamiento. Dado que en la región la onda anual de precipitación presenta dos máximos en las estaciones de transición, se analizó la varianza explicada por esta en función con los períodos a partir de la estimación de los primeros tres armónicos. En la figura 2.8-b se muestran las varianzas explicadas para estimaciones robustas con $\alpha=0$, $\alpha=0.10$ y $\alpha=0.25$. Aquí se observa que a diferencia de la temperatura, la detección de la onda anual de precipitación diaria no es tan clara, con valores de varianza explicada que varían entre 5 y 25% según el período de análisis. Además estas varianzas parecen no estabilizarse a algún valor ni siquiera con los períodos de mayor longitud. Este resultado muestra que para obtener una buena estimación estacional a escala diaria se requiere una gran cantidad de información para filtrar los efectos de alta frecuencia, en este caso mayor a los 100 años de datos diarios. Una solución practica, si se cuenta con períodos menores es la de estimar el promedio diario del día i , $i=1, \dots, 365$, a partir de ventanas de 3 o 5 días centradas en el día i . Este procedimiento incrementa desde 3 a 5 veces la cantidad de información produciendo una estimación más robusta.

2.3.2 Estimación de la onda anual basada en análisis armónico

La idea principal de estos métodos es remover un rango de ciclos de los datos originales. En general existen dos aproximaciones en el análisis de series temporales; el análisis en el dominio de la frecuencia y el análisis en el dominio temporal. El análisis en tiempo utiliza modelos paramétricos para describir las series temporales, mientras que el estudio en frecuencia describe las series utilizando propiedades del comportamiento cíclico de éstas para diferentes frecuencias. Más información sobre estas metodologías se presentan en Jenkins and Watts (1968), Box and Jenkins (1970) and Wei (1993).

Con esta metodología surge la inquietud sobre no solo que período es el que mejor estima la onda anual, sino también que serie es la más apropiada para obtener una mayor varianza explicada. Esto quiere decir, ¿es posible estimarla de la misma manera tomando la serie original con N-datos o es posible mejorar la aproximación considerando la marcha anual de

los promedios diarios con N-años? Además, ¿la mejor estimación detecta las asimetrías de la onda anual observadas?

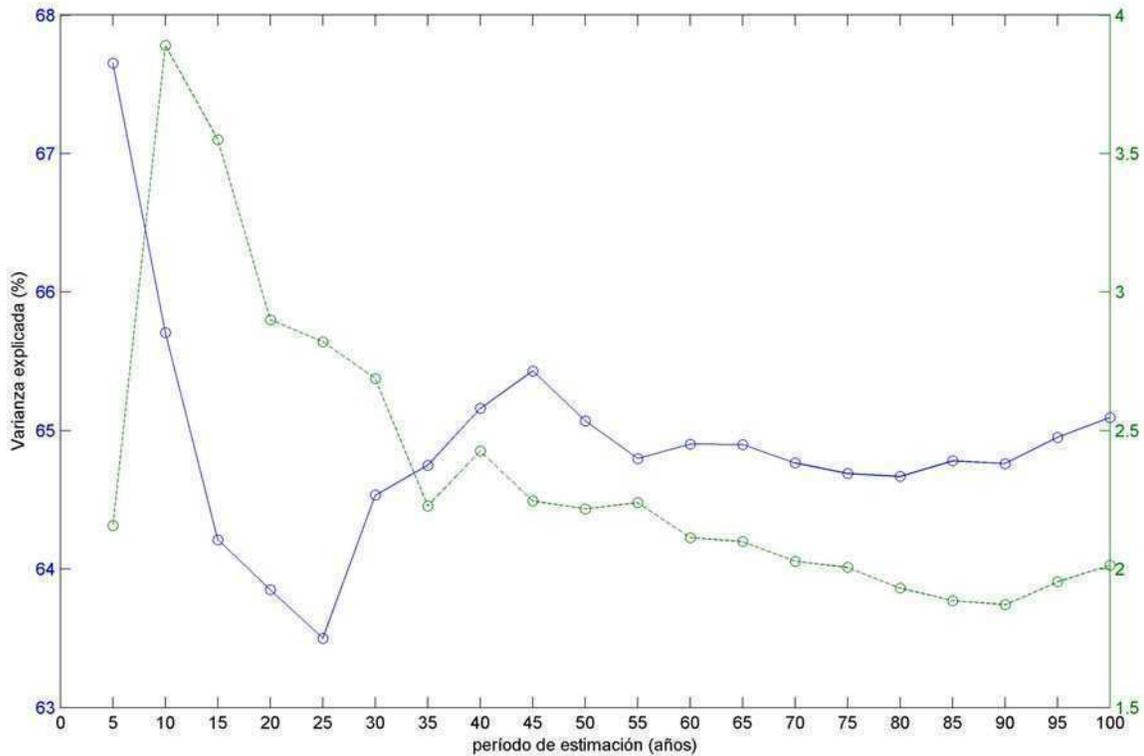


Figura 2.9. Varianza explicada por el armónico que representa la onda anual de temperatura mínima (azul) y varianza explicada por ondas de período mayor a un año (verde) para estimaciones con distintas longitudes de registros ($n \cdot 365$ días).

Supongamos que nuestra serie posee n -años de datos diarios, obtener anomalías a partir de la estimación de cada año, no cumple la primera condición de ser un sistema de referencia fijo, es decir las anomalías de cada año no son comparables con el resto de los años. Además, por estos efectos de alta frecuencia o intraestacionales dependientes de la onda anual pueden ser despreciados.

Ahora, se considera la estimación de la onda anual de la serie de n -años a partir del armónico n . En la figura 2.9 se muestra la varianza explicada por el armónico n , donde se observa que la varianza explicada decrece a medida que se consideran períodos de mayor longitud. Este efecto ocurre principalmente debido a dos causas; al incrementar la cantidad

de datos comienzan a tomar importancia ondas con periodos mayores al de un año e incluso ondas de período mayor a n que son consideradas como tendencias. En particular se observa un mínimo de varianza explicada por la onda anual para periodos entre 20 y 25 años acompañados de un máximo de varianza aportada por ondas de período mayor al año. Además el efecto de los procesos transitorios impone cambios de fase y amplitud año tras año que son detectados por el método produciendo la consiguiente perdida de estabilidad de la estimación.

N° arm	Temperatura máxima			Temperatura mínima			Precipitación		
	Ampl	Var %	V.A. %	Ampl	Var %	V.A. %	Ampl	Var %	V.A. %
1	6.045	96.772	96.772	6.774	98.293	98.293	0.572	16.334	16.334
2	0.737	1.440	98.212	0.719	1.106	99.400	0.336	5.619	21.953
3	0.355	0.333	98.545	0.071	0.011	99.411	0.093	0.436	22.388
4	0.164	0.071	98.616	0.081	0.014	99.425	0.211	2.211	24.599
5	0.187	0.093	98.709	0.193	0.080	99.505	0.103	0.524	25.123
6	0.105	0.029	98.738	0.094	0.019	99.523	0.117	0.682	25.805
7	0.124	0.041	98.779	0.040	0.004	99.527	0.057	0.164	25.969
8	0.107	0.031	98.810	0.074	0.012	99.539	0.089	0.392	26.361
9	0.042	0.005	98.815	0.036	0.003	99.541	0.101	0.505	26.866
10	0.087	0.020	98.835	0.035	0.003	99.544	0.133	0.880	27.745
11	0.141	0.053	98.887	0.119	0.030	99.574	0.066	0.219	27.964
12	0.096	0.024	98.912	0.040	0.004	99.577	0.161	1.299	29.262
13	0.011	0.000	98.912	0.013	0.000	99.578	0.019	0.018	29.280
14	0.043	0.005	98.917	0.016	0.001	99.578	0.039	0.076	29.356
15	0.147	0.057	98.974	0.100	0.022	99.600	0.062	0.190	29.547
16	0.061	0.010	98.984	0.043	0.004	99.604	0.014	0.010	29.557
17	0.181	0.087	99.071	0.080	0.014	99.617	0.162	1.306	30.863
18	0.096	0.024	99.095	0.076	0.012	99.630	0.143	1.026	31.889
19	0.101	0.027	99.122	0.039	0.003	99.633	0.120	0.721	32.609
20	0.043	0.005	99.127	0.087	0.016	99.649	0.067	0.225	32.835
21	0.014	0.001	99.128	0.033	0.002	99.651	0.105	0.544	33.379
22	0.084	0.019	99.146	0.044	0.004	99.655	0.148	1.096	34.475
23	0.120	0.038	99.184	0.061	0.008	99.664	0.132	0.863	35.338
24	0.104	0.029	99.213	0.071	0.011	99.674	0.161	1.299	36.637
25	0.076	0.015	99.228	0.013	0.000	99.675	0.118	0.697	37.333

Tabla 2.1. Amplitud (Ampl.), varianza explicada (var) y varianza acumulada (V.A.) para los primeros 25 armónicos estimados a partir de las marchas anuales de los promedios diarios de temperatura máxima, mínima y precipitación.

En la tabla 2.1 se muestran los primeros 25 armónicos calculados sobre la estimación de la onda anual de promedios diarios, donde se observa para las temperaturas que además de el armónico que representa la onda anual, solo el armónico 2 para la mínima y los armónicos 2 y 3 tienen amplitudes mayores a 0.2 °C. Para la precipitación se tienen valores mucho más bajos de varianza explicada, llegando hasta el 37% con 25 armónicos.

Finalmente, si analizamos la figura 2.8-a se tiene que si se estima la onda anual a partir de los promedios diarios, se tiene una mejora en la estimación a medida que se agranda la muestra con que calcula cada promedio diario, llegando hasta valores de varianza explicada del 98%. El hecho de que la varianza explicada tienda a 98% cuando la cantidad de información se incrementa se debe principalmente a la presencia de asimetrías en la onda anual observada. Esto se observa por la presencia de efectos no lineales producidos por fenómenos transientes recurrentes aunque no periódicos que influyen sobre la pendiente de la onda anual a la entrada y salida de las estaciones de transición.

Dado que la utilización de series de Fourier permite una expresión matemática de variables periódicas, es usualmente difícil visualizar interacciones entre variables relacionadas, más allá del estudio de sus gráficos o a través del análisis de los coeficientes. El análisis vectorial es útil para mostrar proyecciones en planos definidos para indicar interacciones entre variables periódicas con el tiempo (Russel, 1984). Si las variables son medidas como cambios por unidad de tiempo y expresadas como series de Fourier, es posible integrar y diferenciar estas expresiones y ser representadas como funciones vectoriales.

Si consideramos dos variables periódicas, se puede expresar en términos de la función vectorial ($f(t)$) y series de Fourier como sigue;

$$f(t) = \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} a_0 + \sum_{n=1}^m (a_n \cos nt + b_n \text{sennt}) \\ c_0 + \sum_{n=1}^m c_n \cos nt + d_n \text{sennt} \end{pmatrix} \quad (2.9)$$

Si las variables x e y son medidas en términos de cambios por unidad de tiempo, es posible examinar las relaciones entre éstas variables y sus formas diferenciadas como funciones vectoriales. Las series de Fourier se pueden diferenciar (solo si son continuas) término a término y la función vectorial es de la forma;

$$f(t) = \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} \sum_{n=1}^m (-na_n \operatorname{sen} nt + nb_n \operatorname{cos} nt) \\ \sum_{n=1}^m -nc_n \operatorname{sen} nt + nd_n \operatorname{cos} nt \end{pmatrix} \quad (2.10)$$

Donde f es función del tiempo t , x e y son las variables que pueden ser expresadas en términos de series de Fourier; y los coeficientes a_n , b_n , c_n y d_n ($n=0, \dots, m$) definen la serie

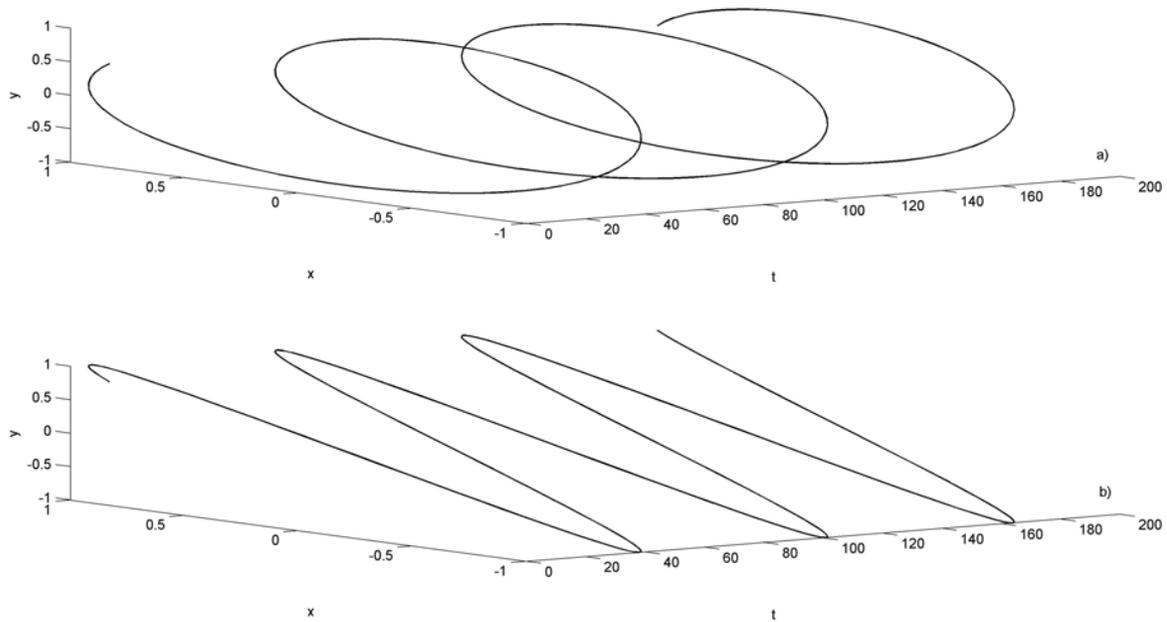


Figura 2.10. Gráfico de la función vectorial $f(t)$ según ecuación (2.9) todos los coeficientes a_n , b_n , c_n y d_n son cero, excepto $b_1=1$ y $c_1=1$, es decir $x(t)=\operatorname{sen}(t)$ e $y(t)=\operatorname{cos}(t)$, (Figura 2.10a) y para $b_1=1$ y $d_1=1$; $x(t)=\operatorname{sen}(t)$ e $y(t)=\operatorname{sen}(t)$ (Figura 2.10b).

de Fourier. En la figura 2.10 se muestran funciones específicas en el espacio tridimensional bajo condiciones específicas donde todos los coeficientes a_n , b_n , c_n y d_n son cero, excepto $b_1=1$ y $c_1=1$, es decir $x(t)=\operatorname{sen}(t)$ e $y(t)=\operatorname{cos}(t)$, (Figura 10-a) y para $b_1=1$ y $d_1=1$; $x(t)=\operatorname{sen}(t)$ e $y(t)=\operatorname{sen}(t)$ (Figura 10-b). Para el primer caso el gráfico de f es una espiral en torno al eje t . La proyección sobre el eje xy es un círculo de radio 1, es decir para series periódicas desfasadas en $\pi/2$ se tiene un proyección circular, mientras que a medida que este desfase cambia, se obtienen proyecciones ovaladas, hasta llegar al segundo caso analizado, donde la proyección sobre el plano xy es un segmento de pendiente -1. La

ecuación 2.9 se ha utilizado para calcular la función vectorial, cuyas componentes están representadas por los promedios diarios de temperatura máxima y mínima diaria en S. M. de Tucumán. La proporción de la varianza explicada por las series de Fourier para ambas series es superior al 96%. En la figura 2.11-a se muestra la proyección de las funciones vectoriales en el plano, asimismo la proyección de los valores de la onda anual calculada con los promedios diarios. La flecha indica la dirección de rotación durante el año. En particular estas proyecciones caracterizan el régimen climático de las interacciones de T_x - T_n al que pertenece la localidad de Tucumán.

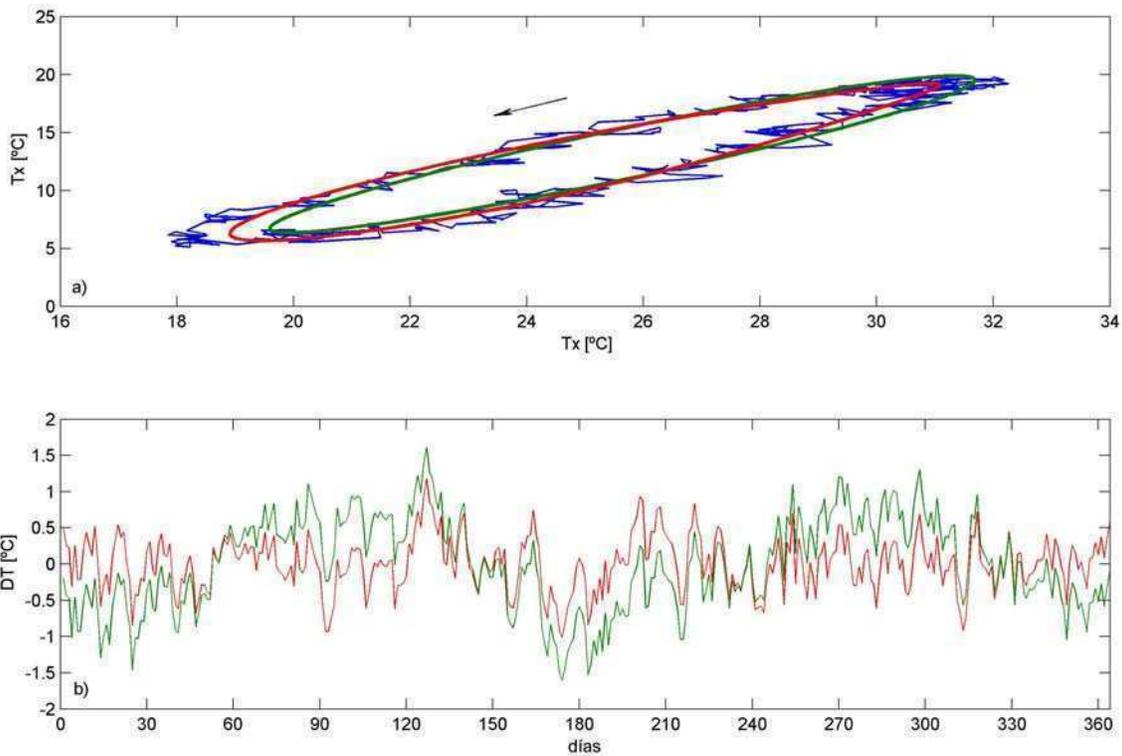


Figura 2.11. Proyecciones de la marcha anual para la temperatura máxima y mínima para la estimación a partir de los promedios diarios (azul), el primer armónico (verde) y la suma del primer y segundo armónico (rojo) (a) y las diferencias entre la onda anual de los promedios de la T_n y las estimaciones de series Fourier (b).

Las mayores diferencias entre las trayectorias se ubican en el invierno donde las estimaciones a partir de las series de Fourier no representan las variaciones de la onda anual

al inicio y fin del invierno y al inicio del verano. Si se analizan las diferencias entre la estimación a partir de los promedios diarios respecto de las series de Fourier considerando el primer armónico y el primer y segundo (figura 2.11-b) se observa la remanencia de una onda semianual, atenuada parcialmente al considerar los dos primeros armónicos, con las mayores diferencias en las estaciones de transición.

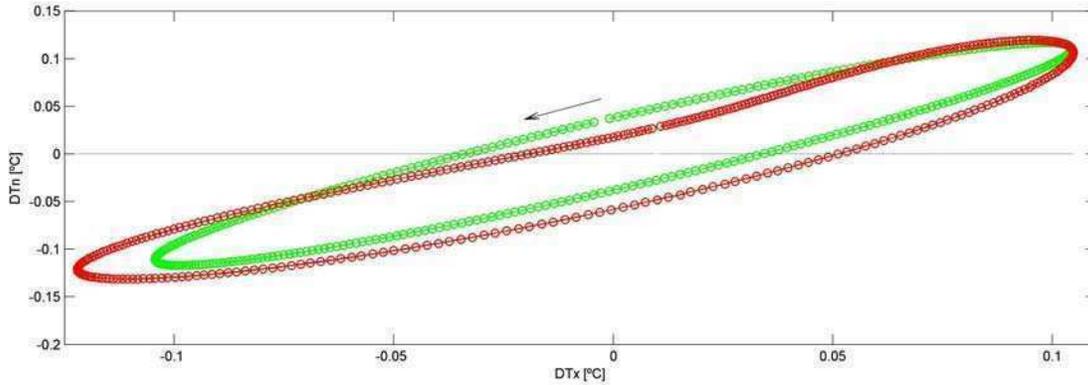


Figura 2.12. Proyección de la forma diferenciada de la función vectorial que representa la onda anual considerando el primer armónico (verde) y el primer y segundo armónico (rojo)

Siguiendo la ecuación 2.10 es posible diferenciar las series de Fourier para obtener la tasa de cambio conjunta entre la temperatura máxima y mínima. En la figura 2.12 se muestran las proyecciones de las formas diferenciadas para las estimaciones de la onda anual considerando solo el primer armónico y considerando los dos primeros armónicos. Aquí se observa que la tasa de cambio es mayor durante el verano para la estimación con dos armónicos mientras esta tasa es menor durante las estaciones de transición y el invierno. Cabe considerar que errores de estimación en estos cambios puede conducir a errores en la estimación de los máximos (día más calido de la onda) y mínimos (día más frío), es decir en la fase de la onda. En la tabla 2.2 se muestran las fechas de ocurrencia del mínimo de la onda calculadas como el día de invierno en que la ecuación 2.10 toma el valor cero. Aquí se observan diferencias entre estimaciones de hasta 7 días principalmente sobre la temperatura mínima. Así mismo se tiene un desfase entre las ondas anuales de la temperatura máxima y mínima de aproximadamente 20 días, efecto que da la forma elíptica de la proyección de la función vectorial estimada según la ecuación 2.9.

	Tx	Tn
OA	17-Jul	03-Jul
AA	19-Jul	30-Jun
AA2	17-Jul	26-Jun

Tabla 2.2. Fecha de ocurrencia del mínimo anual de la onda anual estimada a partir de los promedios diarios (OA), del primer armónico (AA) y de los primeros dos armónicos (AA2)

En la figura 2.13 se muestra la relación entre las estimaciones de la onda anual de temperatura mínima en S.M. de Tucumán a partir de los promedios diarios (OA) y las estimaciones a partir del primer armónico (AA), los primeros dos armónicos (AA2), el método CSD aditivo y CSD multiplicativo. Se observa que en general todas las estimaciones que consideran efectos lineales ajustan bien. Así mismo, las que tienen menor dispersión son aquellas relacionadas con el método CSD y la estimación con los primeros dos armónicos. Pero si se analiza la relación entre la estimación OA y la CSD multiplicativa se observan grandes diferencias principalmente en la representación de los valores extremos.

Dada la presencia de estas asimetrías de la onda anual de temperatura, no se observa una mejora significativa al aplicar los filtros producto del análisis de Fourier, considerando uno o más armónicos. Así mismo estos métodos no son lo suficientemente sensibles para detectar deformaciones importantes en la onda anual, así como singularidades intraestacionales, (Minetti, 1991).

2.4 Estabilidad y robustez de la de Función de autocorrelación y estimaciones espectrales

Las distintas interacciones que existen en las componentes del sistema climático generan perturbaciones y cambios en los procesos que están definidos por su persistencia y propiedades espectrales. En particular la proporción de la relación entre señal-ruido climáticas se encuentra altamente relacionada con la persistencia en la atmósfera (Leith, 1973, 1978). La función de autocorrelación es una buena herramienta para medir el grado de persistencia o dependencia de las observaciones.

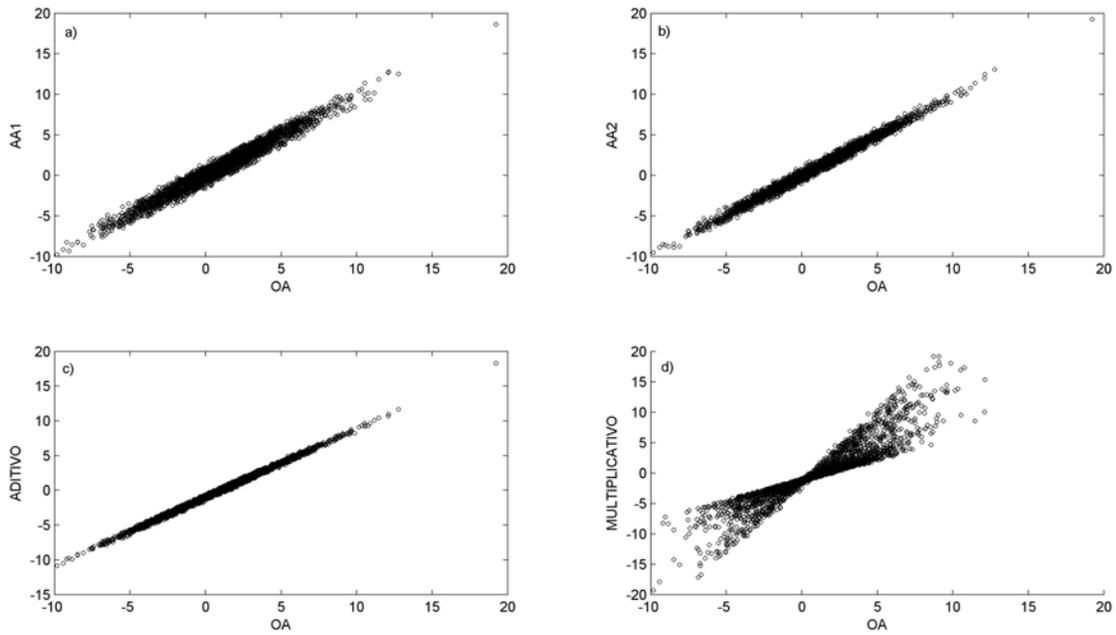


Figura 2.13. Relación entre las estimaciones de la onda anual de temperatura mínima en S.M. de Tucumán a partir de los promedios diarios (OA) y las estimaciones a partir del (a) primer armónico (AA), (b) los primeros dos armónico (AA2), (c) el método CSD aditivo y (d) CSD multiplicativo.

Surge a partir de éstas consideraciones, la pregunta sobre ¿Si existen dependencias entre la función de autocorrelación y el método de filtrado de la onda anual? En la figura 2.14 se muestran las funciones de autocorrelación para los años 1998, 2000, 2002 y 2003 de las anomalías de Tn calculadas según los filtros analizados en la sección anterior. Para los filtros aditivos no se observan diferencias significativas entre las estimaciones, con lo cual los procesos físicos caracterizados por la persistencia y memorias remotas no son alterados por el filtro. Sin embargo, el autocorrelograma que muestra mayores diferencias es el asociado a las anomalías según el método multiplicativo, aunque en general muestra un comportamiento comparable en cuanto a la detección de picos significativos con respecto a las estimaciones aditivas, las mayores diferencias se observan para el año 1998, donde se observa una mayor duración del efecto de la persistencia. Este resultado indica que en ciertas condiciones las interacciones no lineales entre la onda anual y los efectos transientes pueden producir periodicidades no explicadas por los efectos lineales.

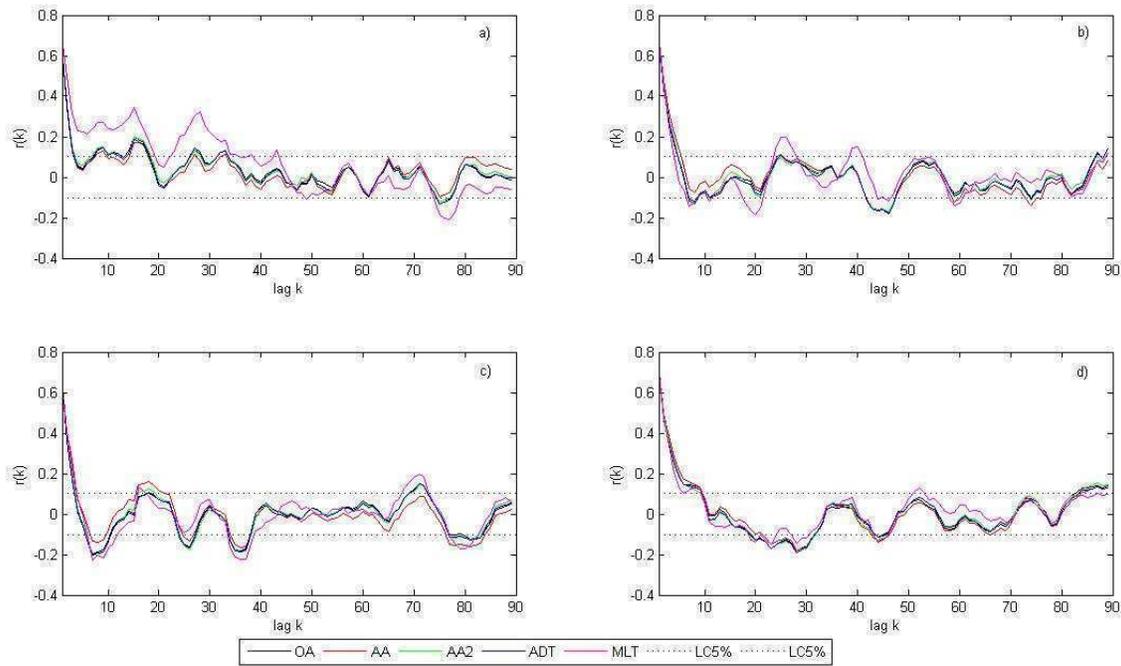


Figura 2.14. Función de autocorrelación para las series de anomalías de temperatura mínima en S. M. de Tucumán para los años (a) 1998, (b) 2000, (c) 2002 y (2004) en referencias a las estimaciones de la onda anual según los promedios diarios (OA), el primer armónico (AA), los primeros dos armónicos (AA2) y la descomposición CSD aditiva (ADT) y multiplicativa (MLT).

En la figura 2.15 se muestran las estimaciones de las funciones de autocorrelación para las series de anomalías de temperatura mínima en S. M. de Tucumán para estimaciones con períodos de distinta longitud (desde 5 hasta 110 años) según los modelos aditivo y multiplicativo estimados a partir de la onda anual según los promedios diarios (OA). Para los períodos mayores a 15 años se observa en ambos casos estimaciones similares donde solo se aprecia la persistencia asociada a un modelo de Markov. Para los períodos mayores a 15 años se observa en ambos casos estimaciones similares donde solo se aprecia la persistencia asociada a un modelo de Markov. Para las otras periodicidades, en particular se observa un pico significativo para oscilaciones de período cercano a 45 días si se consideran los primeros cinco años del registro. Se observa como la significancia de ésta

relación decrece con la longitud del período lo que muestra la dinámica transitoria del proceso físico que generó esa perturbación.

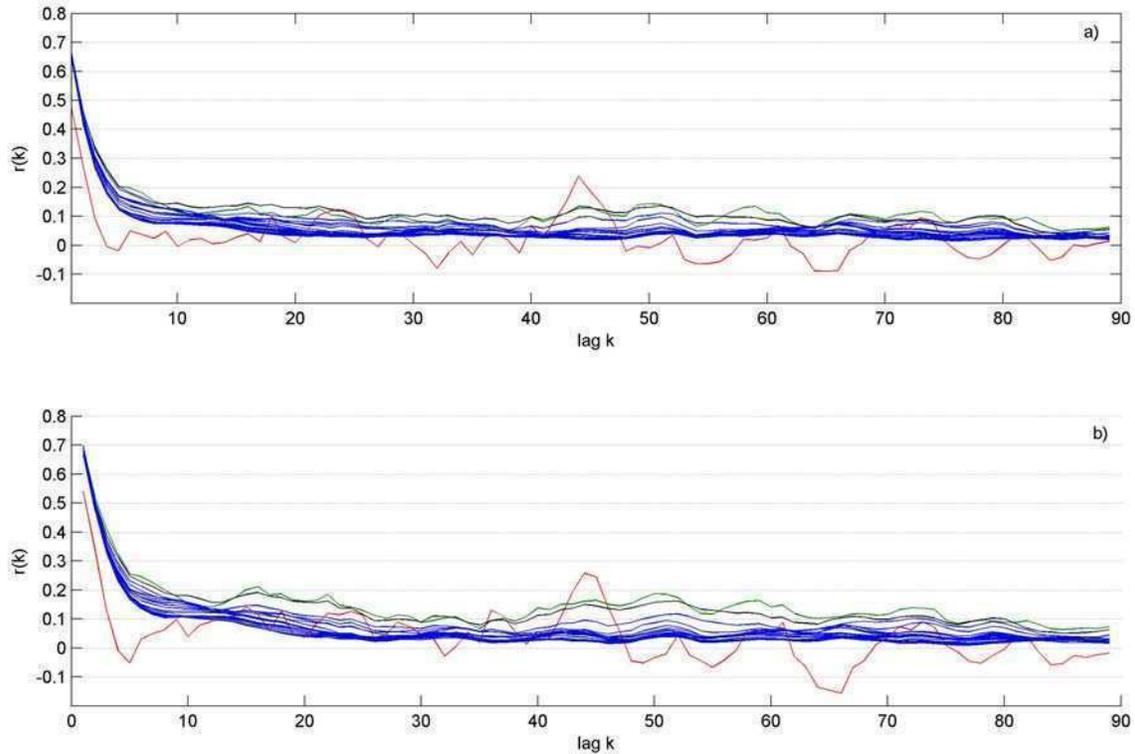


Figura 2.15. Función de autocorrelación para las series de anomalías de temperatura mínima en S. M. de Tucumán para estimaciones en períodos de distinta longitud (5 años en rojo, 10 años en verde, 15 años en negro y mayores a 15 años hasta llegar a 110 años en azul) De acuerdo a los modelos aditivo (a) y multiplicativo (b) según la onda anual según los promedios diarios.

Como primer aproximación parece razonable considerar una serie con la mayor cantidad de información para representar los procesos de alta frecuencia asociados a la persistencia. ¿A partir de que período es posible obtener una estimación estable de la persistencia? En la figura 2.16 se muestran las diferencias entre el coeficiente de autocorrelación (r_k) calculado y el asociado a un proceso Markoviano (r_1^k), con $k=2, \dots, 7$, para estimaciones con períodos de distinta longitud. Se evaluó la significancia de la relación a partir de la hipótesis nula que considera $r_k - r_1^k = 0$ con 5% de confianza. Se observa que para períodos menores a 50 años, los valores de r_k estimados difieren de los que definen el proceso estocástico para

todo k . Si se consideran períodos mayores a 50 años se observa que para las autocorrelaciones con lags de 2 a 5 convergen significativamente a los valores teóricos. Para desfases mayores a 5 días los valores no convergen a los valores de un proceso markoviano indicando en alguna medida el alcance de la persistencia, es decir el tiempo de independencia entre mediciones.

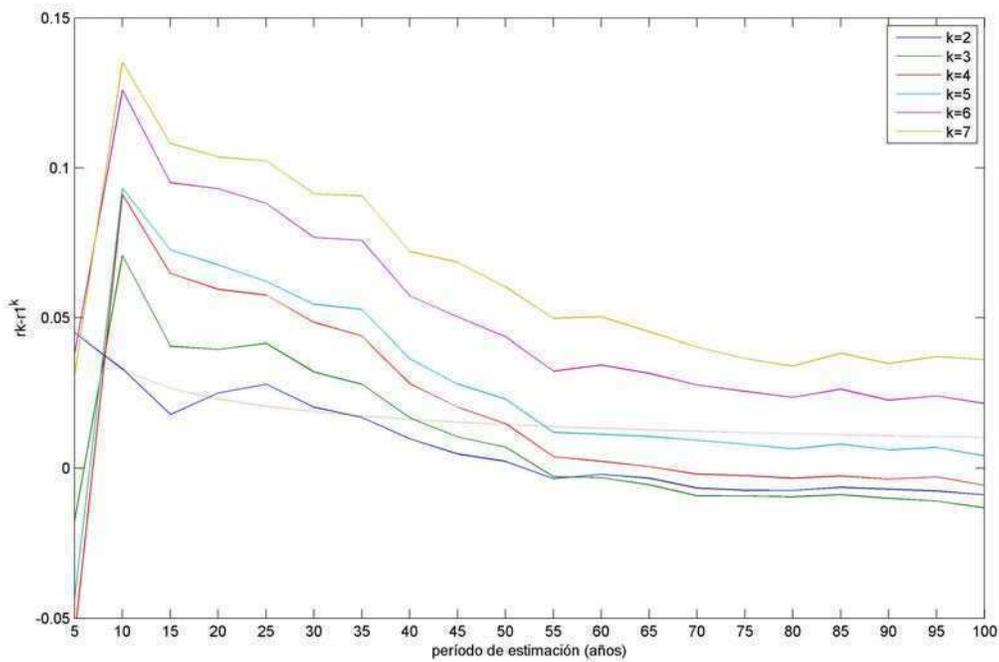


Figura 2.16. Diferencias entre el coeficiente de autocorrelación (r_k) calculado y el asociado a un proceso Markoviano (r_{1k}) para estimaciones con períodos de distinta longitud.

En particular el conocimiento del tiempo de independencia (T_0) entre observaciones es de particular interés en el tratamiento de series temporales asociadas a procesos con persistencia. Bayley y Hammersley (1946) y Trenberth (1984-a) sugieren como el número efectivo de observaciones independientes (N_{eff}) a

$$N_{eff} = N\Delta T / T_0 \tag{2.11}$$

Donde N es el número de datos, ΔT es el paso de tiempo y T_0 es el tiempo de independencia

$$T_o = 1 + 2 \sum_{k=1}^N (1 - k / N) r_k \quad (2.12)$$

Donde r_k es la autocorrelación para el lag k . Si se tiene gran cantidad de información, es decir N es grande se puede aproximar la ecuación (2.12) a

$$T_o \approx \frac{1 + r_1}{1 - r_1} \quad (2.13)$$

Resultados similares a lo discutido en la figura 2.16 se obtienen al analizar la estabilidad de la estimación de T_o (figura 2.17). Se tiene que para períodos mayores a 50 años el valor de T_o para la temperatura mínima se estabiliza en 4.8 días para la estimación lineal de anomalías, mientras que para la estimación multiplicativa el valor tiende a 5.6 días. Este resultado implica que existe una dependencia de T_o con el período analizado, es decir existe una variación interanual de T_o que puede oscilar entre 3 y 7 días. Minetti, 1991 encontró variaciones interanuales del tiempo de independencia de la temperatura máxima en S. M. de Tucumán posiblemente asociados a variaciones entre períodos húmedo/secos.

Además se observa un mayor T_o si se considera el término no lineal de las anomalías, es decir el análisis de ésta componente conduce a estimar efectos más persistentes que se ven afectados por la pendiente de la onda anual. Para los casos mostrados en la figura 2.14, el año 1998 es el que muestra mayores diferencias entre las funciones de autocorrelación para las componentes lineal y no lineal.

Pero, ¿que significa que un año tenga más influencia de los efectos lineales/no lineales? En la figura 2.18 se muestran las distribuciones de secuencias de anomalías positivas y negativas para las temperaturas máximas y mínimas, calculadas según el modelo lineal y multiplicativo. En general para las dos variables se observa una mayor persistencia de las anomalías cálidas si se considera el método multiplicativo. Esto está asociado a procesos advectivos lentos donde las masas de aire cálido permanecen una gran cantidad de días, efecto que se evidencia mejor sobre la temperatura mínima. En cuanto a las secuencias de días fríos, no se observan grandes diferencias entre ambas estimaciones, aunque las variaciones lineales muestran mayor persistencia.

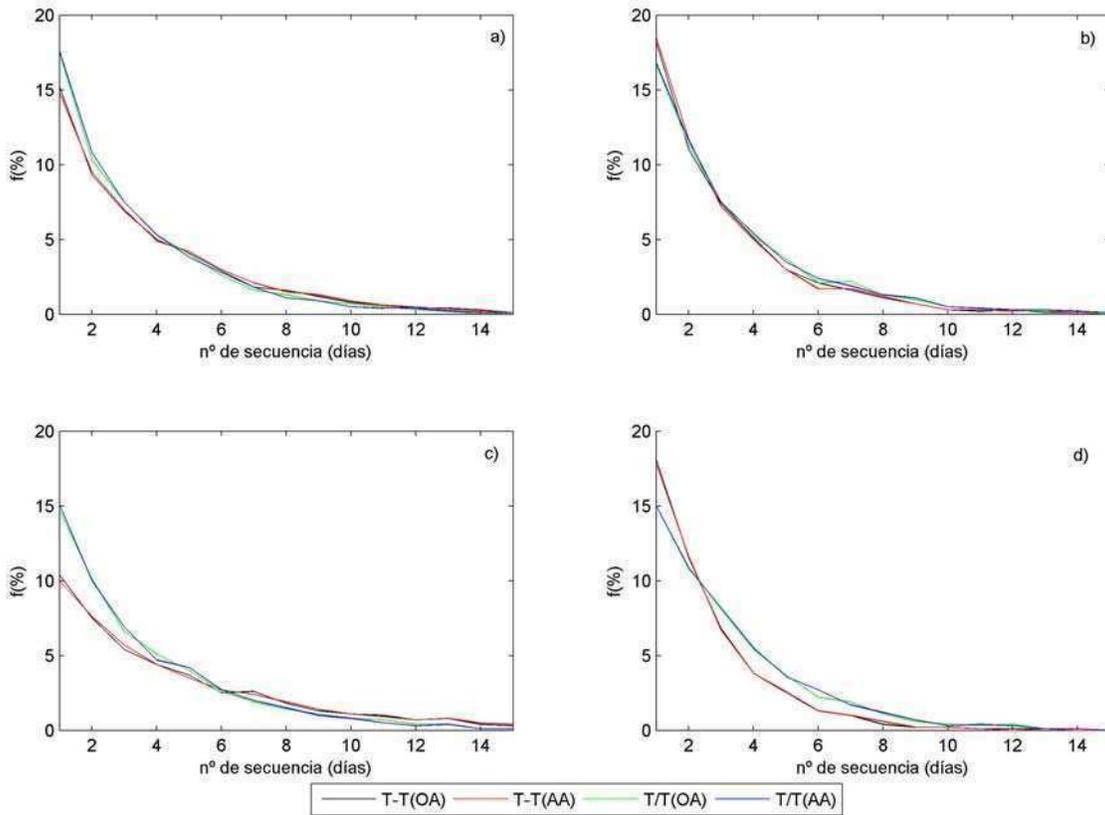


Figura 2.18. Distribución de secuencias de anomalías positivas (a) y negativas (b) de temperatura máxima y de anomalías positivas (c) y negativas (d) de temperatura mínima.

Para el análisis de memorias lejanas, que pueden ser producidas por oscilaciones cuasi-periódicas intermitentes y caracterizadas por ciclos que varían dentro de un rango de frecuencias es de suponer que considerar gran cantidad de información diaria puede influenciar negativamente la detección de éstas periodicidades. Para el caso mostrado en la figura 2.15, se observa un pico significativo asociado a una periodicidad de período cercano a 45 días. En la figura 2.19 se muestra la estimación para períodos de distinta longitud del coeficiente de autocorrelación para el rezago de 45 días, donde se observa que a medida que se incrementa el período analizado, el valor de $r(k=45)$ tiende a cero. Esta es la característica que define a estas perturbaciones asociadas al “ruido climático” pero que son de gran interés a la hora de confeccionar un modelo estocástico.

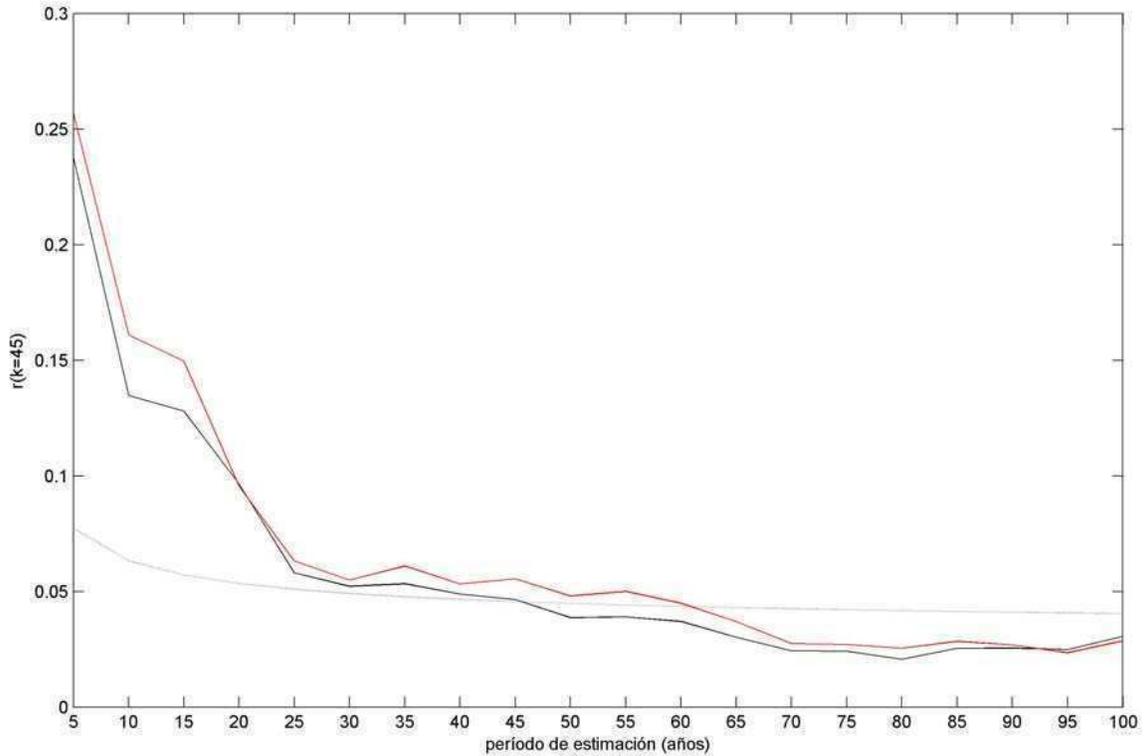


Figura 2.19. Coeficiente de autocorrelación para el lag $k=45$ días para anomalías lineales (negro) y multiplicativas (rojo).

Si se analiza la estimación espectral sobre la misma serie de temperatura mínima (figuras 2.20 y 2.21), se observa que si se toman períodos de estimación mayores a 5 años las perturbaciones de alta frecuencia no son detectadas por el método. Sin embargo, si se comparan las estimaciones espectrales con el continuo nulo (que en este caso representa procesos de ruido rojo) para los distintos períodos se observa que a partir de registros de información mayores a 50-60 años las estimaciones espectrales de períodos mayores a 60-70 días comienzan a converger a los valores teóricos del continuo nulo. Esto no es así para períodos en el ancho de banda comprendido entre 1 y 60 días donde las estimaciones con hasta 100 años de información diaria difiere significativamente del proceso asociado al continuo nulo. Esto indica la presencia de efectos transientes con períodos entre 1 y 60 días con alta recurrencia que modifican la estructura espectral.

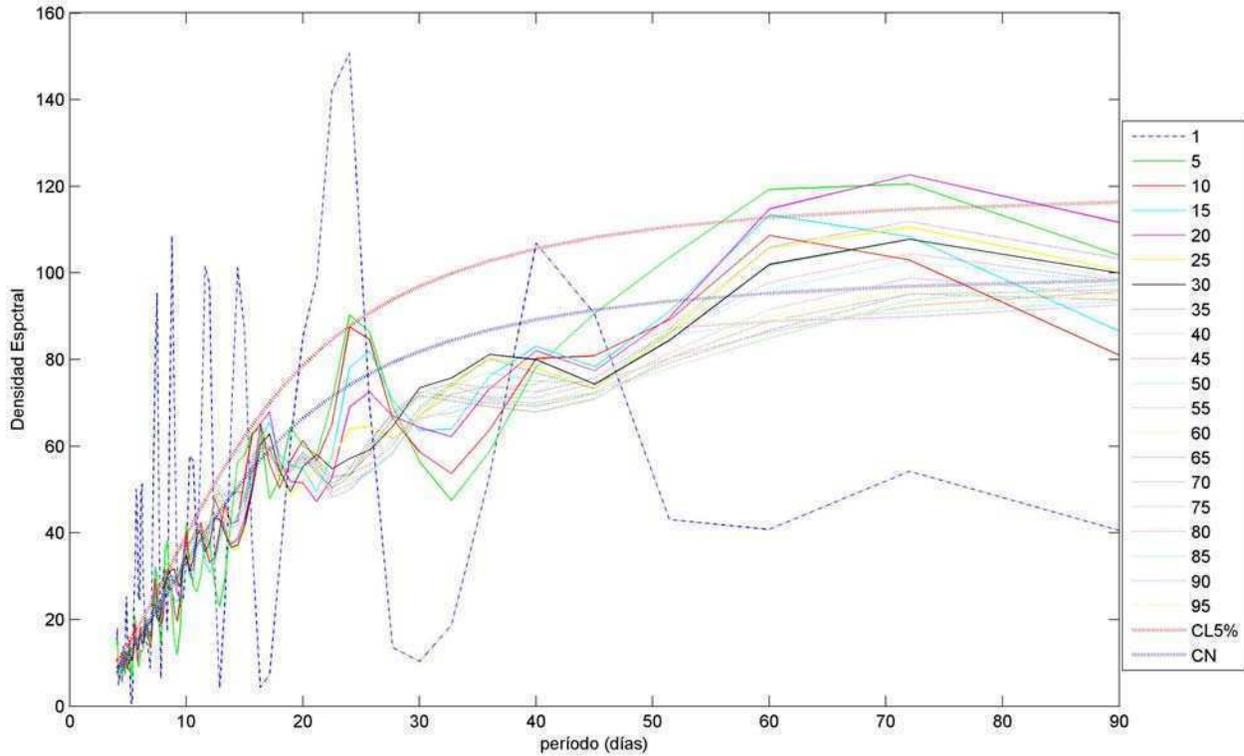


Figura 2.20. Estimación espectral para las series de anomalías de temperatura mínima en S. M. de Tucumán para estimaciones en períodos de distinta longitud (desde 1 a 100 años) de acuerdo a los modelos aditivo.

Si no consideramos los procesos asociados con la escala sinóptica es posible inferir que los procesos con períodos entre 30 y 60 días conservan en alguna medida efectos de la memoria remota del sistema. Por la naturaleza de estos procesos cuando uno desea analizar la influencia de procesos que muestran autocorrelaciones lejanas (es decir, más allá de las asociadas a un proceso de ruido rojo) es necesario diseñar para el análisis, ventanas de tiempo de dimensiones comparables al período de la onda que se desea describir.

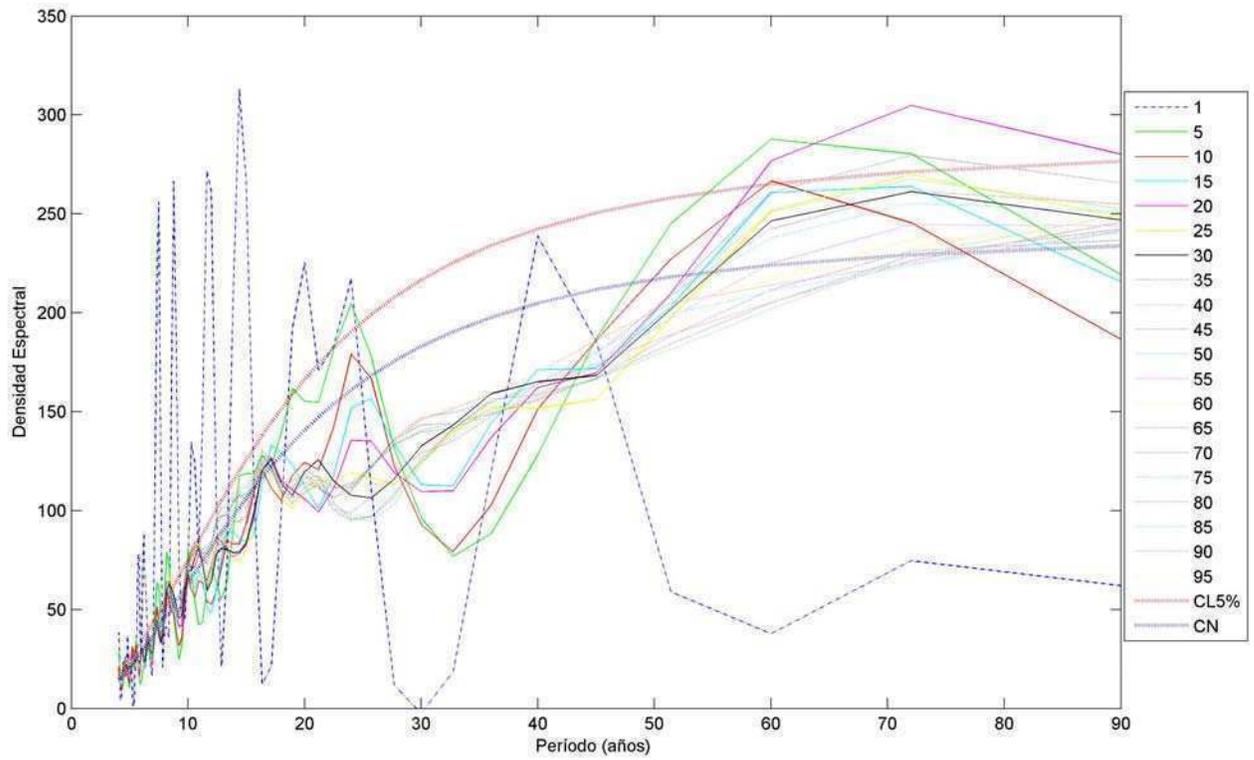


Figura 2.21. Estimación espectral para las series de anomalías de temperatura mínima en S. M. de Tucumán para estimaciones en períodos de distinta longitud (desde 1 a 100 años) de acuerdo al modelo multiplicativo.

CAPITULO 3

ANALISIS DE LA PERSISTENCIA SOBRE LA TEMPERATURA MAXIMA Y MINIMA DIARIA

Como primera aproximación, en el estudio de la variabilidad en la atmósfera se pueden clasificar a grandes rasgos en dos escalas temporales principales, comúnmente denominadas como tiempo y clima. El tiempo refiere al comportamiento de la atmósfera sobre períodos de varios días, debidos principalmente a la inestabilidad interna del sistema. El Clima trata generalmente sobre el comportamiento medio del sistema o procesos de baja frecuencia, que generalmente se encuentran condicionados por procesos físicos asociados a las condiciones de borde de la atmósfera.

Además por la amplitud de los eventos de alta frecuencia un estado climático está sujeto a fluctuaciones estocásticas en general impredecibles en las escalas temporales de interés climático (Trenberth, 1984b, Madden and Shea, 1978). Sin embargo, una parte de la variabilidad natural asociada con la evolución de ondas de baja frecuencia puede mejorar la predictabilidad del sistema (Shukla, 1981a-b, 1998).

La asociación entre anomalías diarias de una variable meteorológica entre diferentes días que no es producto de la persistencia puede ser una evidencia de una interacción no lineal entre una perturbación aperiódica y la onda anual (Minetti y Vargas, 1997b). En función de estas asociaciones y como primer aproximación a un modelo de pronóstico objetivo la mayoría de las variables meteorológicas pueden ser aproximadas por un proceso Markoviano. Se entiende al proceso de primer orden de Markov (autoregresivo), también referido como ruido rojo, a los procesos que están dominados por componentes de baja frecuencia, éste se puede definir como;

$$x_i = \alpha x_{i-1} + \varepsilon_i \quad (3.1)$$

Donde x_i es la variable analizada, α es el coeficiente de autocorrelación para el lag 1 y ε_i representa el ruido blanco, que caracteriza a los procesos aleatorios, en el tiempo $t=i\Delta t$. Dada las características de las series de temperatura diaria, aumentar el conocimiento de los procesos autoregresivos de órdenes mayores, permitiría obtener mejoras en los diagnósticos y pronósticos objetivos asociados a esta variable.

La primer herramienta que se presenta en este trabajo para explorar estas relaciones, es a través de la función de autocovarianza y autocorrelación. A partir de esta metodología es posibles explorar las asociaciones internas de las series de temperatura.

3.1 Estimación de la función de autocorrelación

Las autocovarianzas muestrales al lag k, C_k , se pueden estimar como

$$C_k = \frac{1}{N} \sum_{i=k+1}^N (x_{i+k} - \bar{x})(x_i - \bar{x}) \quad (3.2)$$

donde \bar{x} es la media de una muestra con N datos. Además C_0 representa la varianza total de la muestra,

$$C_0 = S_x = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (3.3)$$

Con estos elementos, el coeficiente de autocorrelación para el lag k se puede definir como;

$$r_k = \frac{C_k}{C_0} \quad (3.4)$$

Según la definición de la ecuación (3.4) se obtiene la función de autocorrelación a nivel climático. Sin embargo, para muchas aplicaciones es de interés conocer el comportamiento entre las asociaciones para distintos períodos o submuestras según sea el problema que se desea tratar.

Por ejemplo, si se desea analizar la variabilidad interanual de la función de autocorrelación es posible dividir la serie en muestras de N observaciones para J años. A partir de esto, se proponen dos posibles aproximaciones para estimar las autocovarianzas.

Si x_{ij} es el i-esimo día para el año j, se define

$$C_{k,j} = \frac{1}{N} \sum_{i=k+1}^N (x_{i+k,j} - \bar{x}_j)(x_{i,j} - \bar{x}_j) \quad (3.5)$$

donde

$$\bar{x}_j = \frac{1}{N} \sum_{i=1}^N x_{i,j} \quad (3.6)$$

es la media muestral. A partir de estos elementos, es posible definir el coeficiente de autocorrelación en el lag k del año j, como

$$r_{k,j} = \frac{C_{k,j}}{C_{0,j}} \quad (3.7)$$

y

$$r_k = \frac{1}{J} \sum_{j=1}^J r_{k,j} \quad (3.8)$$

es la autocorrelación total.

Otra forma posible es definir

$$C_{k,j} = \frac{1}{N} \sum_{i=k+1}^N (x_{i+k,j} - \bar{x}_j)(x_{i,j} - \bar{x}_j) \quad (3.9)$$

donde

$$\bar{x}_j = \frac{1}{NJ} \sum_{j=1}^J \sum_{i=1}^N x_{i,j} \quad (3.10)$$

es la media sobre todas las observaciones. Por consiguiente la autocovarianza total es,

$$C_k = \frac{1}{J} \sum_{j=1}^J C_{k,j} \quad (3.11)$$

y la autocorrelación

$$r_k = \frac{C_k}{C_0} \quad (3.12)$$

La principal diferencia entre estas estimaciones es el uso de medias para cada muestra (ecuación 3.5), que permite comparar la variabilidad interna de la persistencia y asociaciones lejanas de cada año, mientras que según la ecuación (3.9) se utiliza la media total.

Por otro, lado si se desea analizar la persistencia y asociaciones distantes en el tiempo los métodos descritos por las ecuaciones (3.5) y (3.9) no proporcionan esta información a nivel diario. Por esto, con el fin de definir las relaciones o memorias de la serie para días particulares se puede definir la función de autocovarianza para cada día del año a partir de N años de información como;

$$C_{k,i} = \frac{1}{N} \sum_{i=k+1}^N (x_{i+k} - \bar{x}_i)(x_{i+k} - \bar{x}_i) \quad (3.13)$$

donde $i=1,\dots,365$ representa el día del año a partir del cual se calcula la función de autocorrelación, que se expresa como

$$r_{k,i} = \frac{C_{k,i}}{C_{0,i}} \quad (3.14)$$

Se entiende en esta representación, por ejemplo, que el valor de $r_{1,1}$ representa el primer coeficiente de autocorrelación con $k=1$ y para el día $i=1$. Esta es la asociación de la serie del 1 de enero con el 2 de enero, para $k=2$ se tiene la asociación entre el 1 y 3 de enero, mientras que para el lag $k=n$ ($n=1,\dots,365$) es la asociación entre el 1 de enero con el día del año n .

La presencia de tendencias seculares puede alterar el grado de independencia entre observaciones y por consiguiente afectar las estimaciones de la función de autocorrelación. Por este motivo las series de temperatura diarias han sido filtradas mediante cuadrados mínimos para asegurar que las series cumplan con la condición de estacionariedad en los valores medios.

3.2 Evolución anual de la persistencia en las series de Temperatura máxima y mínima

El primer coeficiente de autocorrelación ($k=1$) es de particular importancia dado que este es el que define los procesos de ruido rojo y modelos autoregresivos como el descrito en la ecuación (3.1). Por esto, es necesario determinar si un modelo calculado a partir de toda la muestra, por ejemplo según los métodos descritos en la ecuación (3.5) o (3.9), es válido para ser utilizados en cualquier época del año o es necesario un mayor nivel de detalle para obtener una mejor aproximación a los procesos físicos que conforman la persistencia.

En las figuras 3.1 y 3.2 se muestran las marchas anuales de los tres primeros coeficientes de autocorrelación (para lags $k=1$, $k=2$ y $k=3$) calculados utilizando la expresión de la ecuación (3.14) para la temperatura máxima y mínima sobre las ocho estaciones de referencia. Estas ocho estaciones de referencia definidas de esta manera por la longitud de sus períodos y calidad de medición, representan las principales regiones climáticas en el sudeste de Sudamérica. Campinas, Corrientes y San Miguel de Tucumán representan las

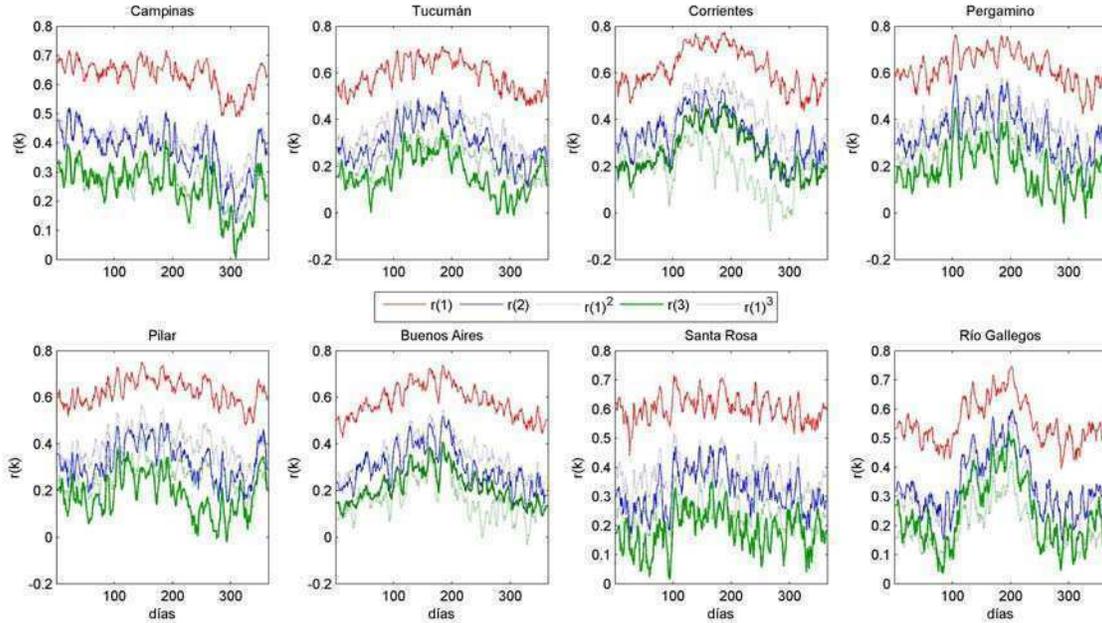


Figura 3.1. Marcha anual de los tres primeros coeficientes de autocorrelación de la temperatura máxima en ocho estaciones de referencia, r_1 (rojo), r_2 (azul) y r_3 (verde) y sus correspondientes valores asociados al proceso markoviano de cada día (línea punteada).

diferentes características de clima de los subtropicos con variaciones en los efectos de continentalidad (desde marítimo a continental respectivamente). Las estaciones que describen la transición entre el subtropico y las latitudes medias (Buenos Aires, Pergamino y Pilar), mientras que Santa Rosa evidencia un mayor predominio de los procesos de latitudes medias, y finalmente Río Gallegos al sur del continente es la representación de las latitudes medias.

En general, si se analiza la marcha anual de correlaciones entre cada día y el siguiente (r_1) se observan las mayores persistencias en los meses de invierno, destacándose que las transiciones hacia y desde la época fría se dan de forma asimétrica. Para la temperatura máxima (figura 3.1) el comportamiento regional es más heterogéneo, pero en general se observa una transición más rápida desde el otoño al invierno, mientras que en primavera la transición a procesos de menor persistencia es más suave. Este hecho es más evidente en Corrientes donde se observa un rápido aumento de los r_1 cerca del día 100 (10 de abril) hasta alcanzar el máximo 20 días después. Así mismo, en ésta localidad se observa una variación de menor pendiente desde el invierno hasta la primavera.

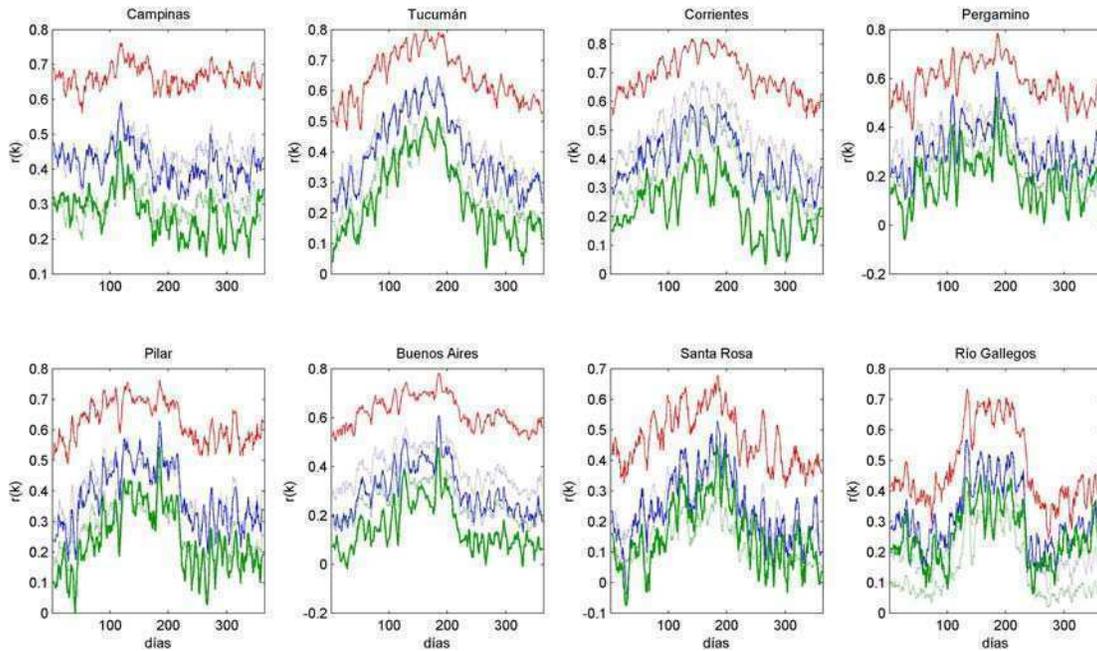


Figura 3.2. Marcha anual de los tres primeros coeficientes de autocorrelación de la temperatura mínima en ocho estaciones de referencia, r_1 (rojo), r_2 (azul) y r_3 (verde) y sus correspondientes valores asociados al proceso markoviano de cada día (línea punteada).

Las mayores singularidades se observan en las estaciones ubicadas en los extremos de la región de análisis. En Campinas no se observa una onda anual clara, aunque la mayor variación se observa en primavera donde se registra un mínimo marcado desde el día 270 (27 de setiembre) al 310 (6 de noviembre). Por otro lado, en Río Gallegos se observa la variación anual más marcada con valores de r_1 alrededor de 0.55 en verano, rápidos cambios en otoño y primavera para alcanzar valores cercanos a 0.7 en invierno (Los valores entre verano e invierno son significativamente distintos con un nivel de confianza de 5%).

Para la temperatura mínima se observa un comportamiento regional más homogéneo, donde en la totalidad de las estaciones de referencia, excepto Campinas, se observa una mayor tasa de variación de la persistencia entre el invierno y la primavera, al contrario de lo que ocurre con la temperatura máxima. Este cambio en la persistencia en general está centrado en los días cercanos al 220 (8 de agosto). Así mismo, en Campiñas se observa la época de mayor persistencia durante el otoño.

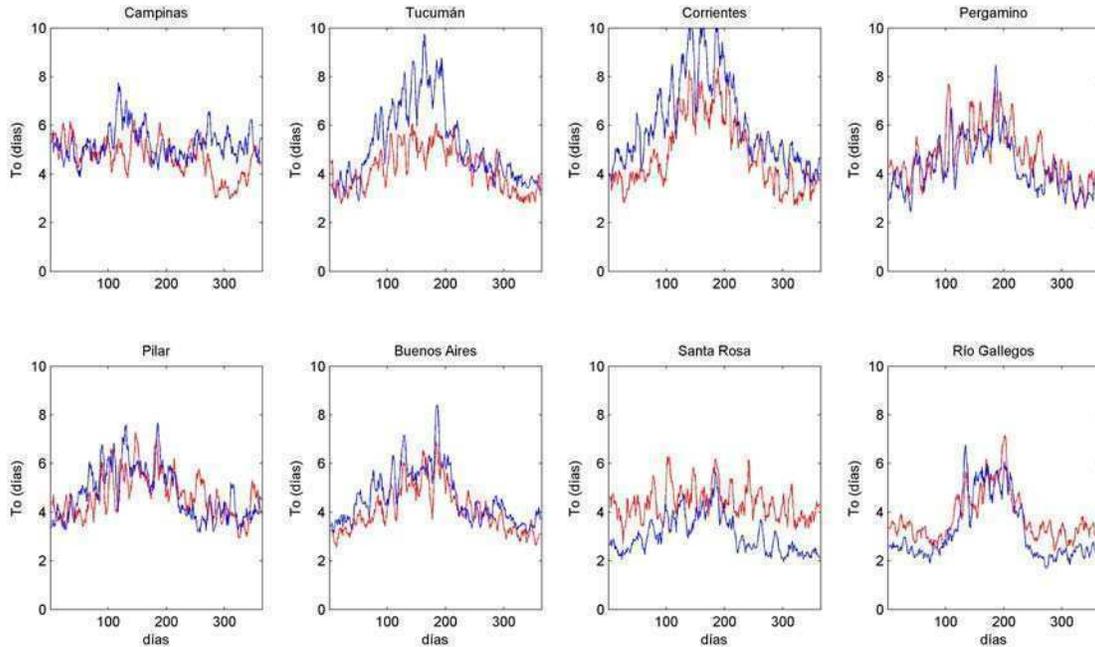


Figura 3.3. Marcha anual del tiempo de independencia (To) entre observaciones para la temperatura máxima (rojo) y mínima (azul) en ocho estaciones de referencia.

De esto, se desprende que para la temperatura máxima, variable altamente dependiente de la nubosidad, y para la temperatura mínima mayormente influenciada por las irrupciones frías/cálidas, los cambios observados están reflejando en cierto modo los procesos que conducen al comienzo o finalización de la temporada fría y seca. Por este motivo si se desea representar la persistencia en estas variables es necesario un mayor detalle durante las estaciones de transición, principalmente el otoño en la temperatura máxima y en primavera para la temperatura mínima, donde en general los primeros coeficientes de autocorrelación varían más rápidamente.

Los coeficientes de autocorrelación mayores, en particular para los lags 2 y 3 muestran un comportamiento similar al de la marcha anual de r_1 y en general en la región siguen el comportamiento asociado a procesos markovianos ($r_k=r_1^k$). Las series que más se apartan de éste modelo de persistencia son las temperaturas máximas de Buenos Aires y Corrientes, donde en primavera la relación entre el día i con el $i+2$ responde a procesos de mayor frecuencia respecto al markoviano, mientras que la relación con el día $i+3$ muestra una

mayor persistencia siempre comparados con procesos de ruido rojo. Para la temperatura mínima en estas dos localidades se observa un apartamiento de los procesos de Markov para los lags 2 y 3, siendo durante todo el año la persistencia observada de menor magnitud.

Una consecuencia inmediata que se desprende del análisis anterior es que el tiempo de independencia entre observaciones (T_o) posee variaciones interestacionales. En la figura 3.3 se muestran las marchas anuales para T_o calculadas sobre la temperatura máxima y mínima en las ocho estaciones de referencia. Este valor se puede calcular asociado a cada día (i) del año según las ecuaciones (2.12) y (3.14), como

$$T_{o_i} = 1 + 2 \sum_{k=1}^{N_i} (1 - k / N_i) r_{k,i} \quad (3.15)$$

Donde $r_{k,i}$ es la autocorrelación para el lag k del día i .

Si la cantidad de información es grande se puede aproximar según;

$$T_{o_i} \approx \frac{1 + r_{1i}}{1 - r_{1i}} \quad (3.16)$$

donde $i=1, \dots, 365$ representa el día del año y r_{1i} es la correlación del día i con el siguiente estimado de acuerdo a la ecuación (3.14).

En general, para las estaciones ubicadas en los subtrópicos y regiones de transición, el tiempo de independencia es menor para la temperatura máxima debido a que ésta región se encuentra más afectada por la evolución de la nubosidad y la precipitación. Por otro lado la temperatura mínima tiende a conservar en mayor medida las propiedades termodinámicas de las masas de aire al estar menos influenciada por la nubosidad. En las estaciones de latitudes medias este resultado solo es verdadero en invierno, mientras que para el resto del año el tiempo de independencia entre observaciones es mayor para la temperatura mínima. Si se considera la variabilidad interestacional del tiempo de independencia que se observa para la región, se tienen variaciones de entre 3 y 7 días para la temperatura máxima y entre 2 y 10 días para la mínima, con máximos en invierno y mínimos en verano. Si se considera éste resultado, en lugar de considerar el valor medio de T_o (ecuación 2.12) es posible mejorar sensiblemente el número de observaciones independientes para las series de tiempo analizadas. Recordando que el número efectivo de observaciones (N_{eff}) es función de la

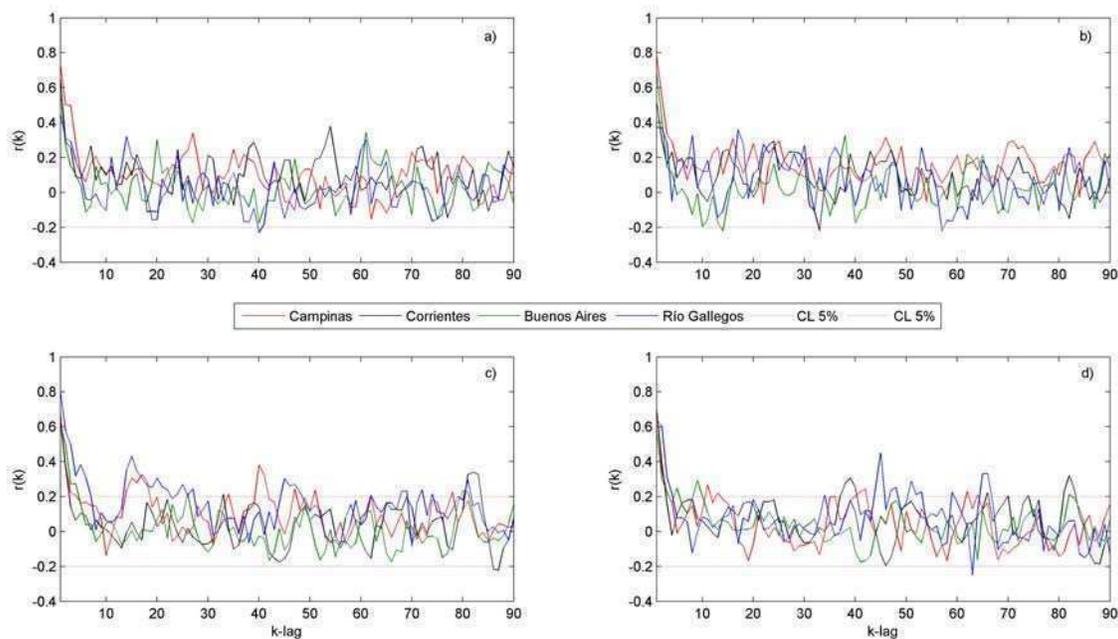


Figura 3.4. Coeficientes de autocorrelación para el lag k , con $k=1\dots 90$ días para la temperatura máxima (a, c) y mínima (b, d) en cuatro estaciones de referencia para el 1° de enero (a y b) y 1° de julio (c y d).

cantidad de datos y del tiempo de independencia, según lo definido en la ecuación (2.11) y si se considera el tiempo de independencia T_{oi} para el día i del año, es posible redefinir N_{eff} como,

$$N_{eff} = \sum_{i=1}^{365} \frac{N_i \Delta T}{T_{oi}} \quad (3.17)$$

Donde N_i es la cantidad de años que se observó el día i . Es decir conocido el tiempo de independencia para el día i solo se remueven T_{oi} (ecuación 3.15) días en vez de T_o días (ecuación 2.12). Este procedimiento particularmente útil en series con marcada persistencia, permite optimizar la cantidad de información en el caso de ser necesario remover datos para obtener observaciones independientes.

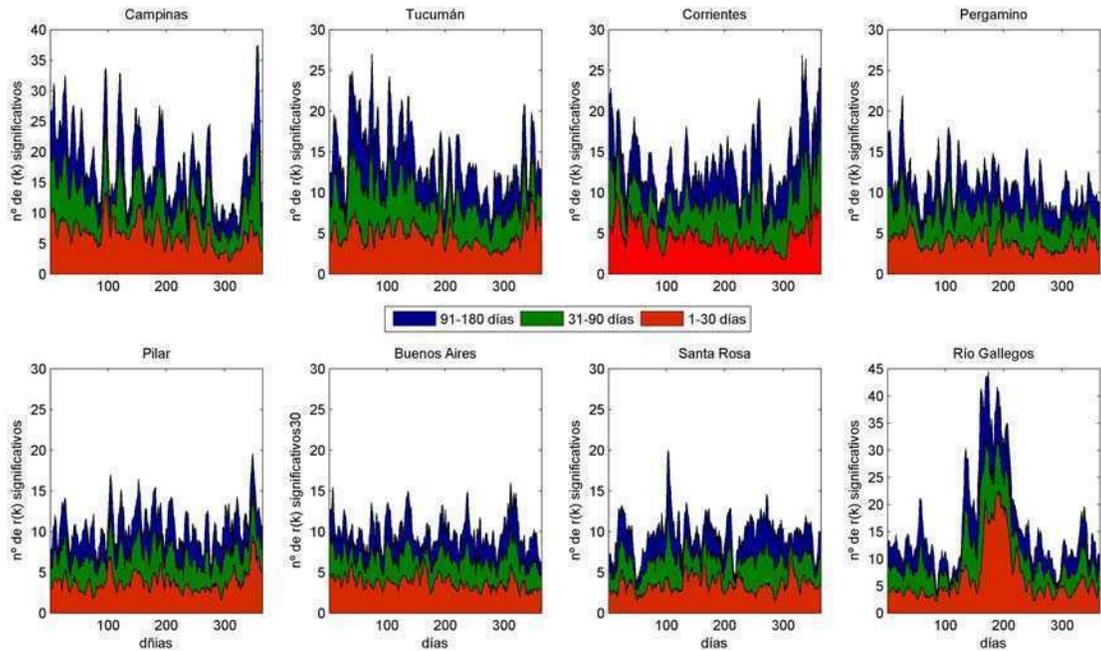


Figura 3.5. Marcha anual de la cantidad de coeficientes de autocorrelación significativos para la temperatura máxima en ocho estaciones de referencia para lags entre 1-30 días (rojo), 31-90 días (verde) y 91-180 días (azul).

3.3 Evolución anual de las memorias lejanas en las series de Temperatura máxima y mínima

Como introducción al problema asociado a las memorias lejanas de las series de temperatura, se presentan las funciones de autocorrelación para algunos días específicos. En la figura 3.4 se muestran las funciones de autocorrelación para el 1° de enero y de 1° de julio ($r_{k,1}$ y $r_{k,182}$ respectivamente) en Campinas, Corrientes, Buenos Aires y Río Gallegos. En los primeros lags, se puede observar el comportamiento de la persistencia con una variación estacional según lo descrito en la sección anterior. Los primeros coeficientes de autocorrelación significativos, sin que las dependencias se interrumpan, varían entre tres y siete días dependiendo de la latitud y época del año.

Además de los primeros coeficientes de autocorrelación significativos asociados directamente a la persistencia, se observan asociaciones distantes significativas en distintos rezagos. Estas correlaciones significativas distantes y que no son persistentes se las pueden

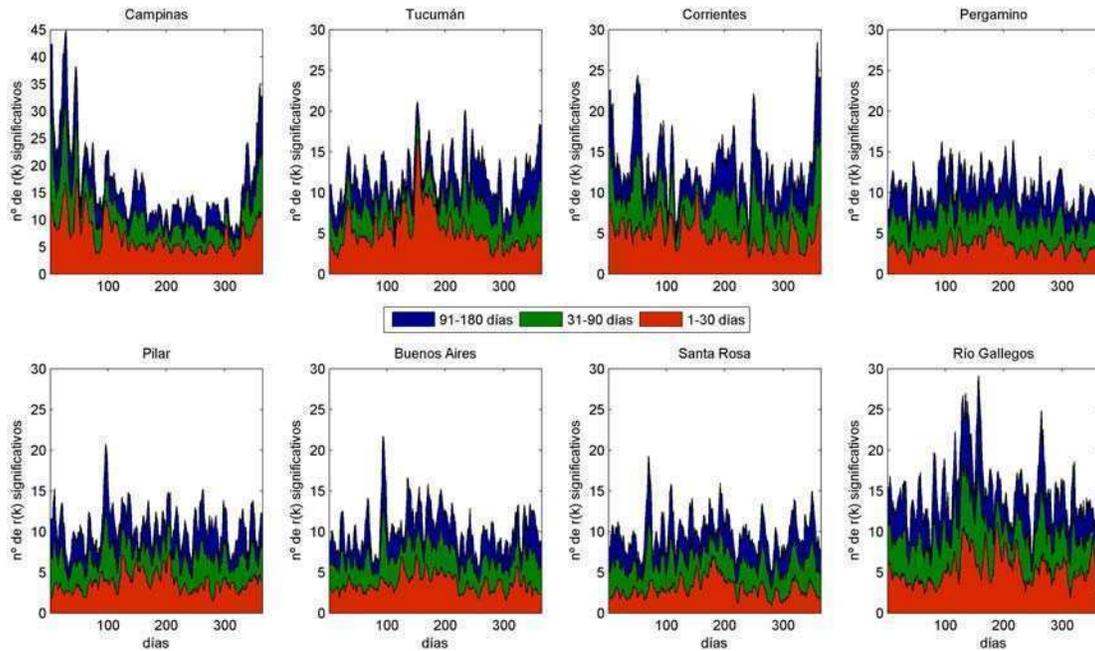


Figura 3.6. Marcha anual de la cantidad de coeficientes de autocorrelación significativos para la temperatura mínima en ocho estaciones de referencia para lags entre 1-30 días (rojo), 31-90 días (verde) y 91-180 días (azul).

denominar síntomas precursoros. Este término ha sido utilizado inicialmente por Borisova y Rudiceva (1968) y hace referencia a los síntomas anticipativos asociados a diferentes condiciones atmosféricas particulares. Este comportamiento antecedente depende de la época del año y algunos de ellos pueden estar asociados a episodios estacionales o singularidades climáticas intraestacionales específicas, Minetti y Vargas (1997).

En las figuras 3.5 y 3.6 se muestran las marchas anuales de la cantidad de coeficientes de autocorrelación significativos para la temperatura máxima y mínima en las estaciones de referencia discriminadas para los desfases entre los intervalos de 1-30, 31-90 y 91-180 días. La mayor cantidad de asociaciones significativas evidencia la época del año donde es posible encontrar una mayor cantidad de precursoros.

A partir del análisis de estas figuras se desprende que existe una mayor cantidad de asociaciones lejanas en las estaciones subtropicales, con días particulares que superan los veinte valores significativos. Sobre las estaciones ubicadas en el centro de Argentina, también son evidentes algunas épocas del año con mayor cantidad de precursoros, aunque

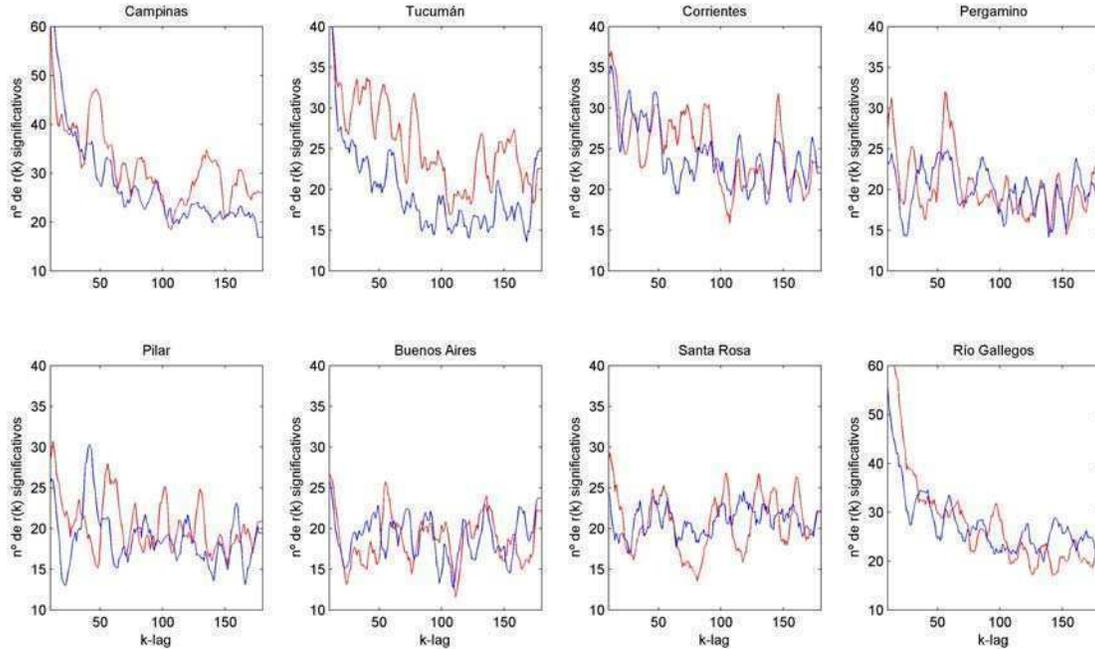


Figura 3.7. Cantidad de coeficientes de autocorrelación significativos para el lag k , con $k=1\dots 180$ días para la temperatura máxima (rojo) y mínima (azul) en ocho estaciones de referencia.

en general son pocos los días del año con más de quince asociaciones significativas. Finalmente, Río Gallegos es la única localidad que muestra una marcada onda anual en esta variable donde la mayor cantidad de coeficientes de autocorrelación significativos ocurre en invierno.

En resumen, existen épocas del año particulares donde las series de temperatura evidencian una mayor cantidad de relaciones remotas, con lo cual surge la pregunta, ¿Existe algún período en particular o desfase que tiende a recurrir más que otro? En la figura 3.7 se muestran la cantidad de coeficientes de autocorrelación significativos para el lags entre 1 y 180 días para la temperatura máxima y mínima en las estaciones de referencia.

En las estaciones subtropicales y en Río Gallegos, se observa una dependencia de la frecuencia de autocorrelaciones significativas con los desfases. Esta dependencia se representa como un decrecimiento de este parámetro hasta aproximadamente el lag 100, donde tiende a estabilizarse. En las otras estaciones no se observa éste efecto, aunque una

característica en común en todas las estaciones es la presencia de picos o máximos de frecuencias significativas asociados a distintos desfases. Dada la importancia de esta información, se hace un análisis detallado de las singularidades de estas funciones, ya que las regiones de máximos pueden sugerir la presencia de ondas específicas asociadas a períodos particulares. Sobre las estaciones tropicales/subtropicales (Campinas, Tucumán y Corrientes) se observa una preferencia a la ocurrencia picos significativos entre 30, 50, 70 y 120 días. En Pergamino, Buenos Aires y Pilar hay picos entre 60, 90 y 120 días. Finalmente en Santa Rosa y Río Gallegos se observan como desfases peculiares a los centrados entre 40, 60, 120 y 150 días.

En la tabla 3.1 se resume la información detallada anteriormente. En general, en la mayoría de estaciones de referencia se observa una mayor predisposición a tener ciclos entre 30 y 120 días, aunque en todas se observa la presencia de ciclos o cuasi-ciclos entre 30 y 60 días. Este resultado se puede asociar a la preferencia de ocurrencia de diferentes oscilaciones aperiódicas en diferentes épocas del año y quizás en años con características físicas particulares.

Con todos los elementos detallados en esta sección, es posible desprender una aplicación directa del análisis. Por esto, de acuerdo a lo descrito anteriormente y en concordancia con lo propuesto por Minetti y Vargas (1997) es posible proponer dos modelos de pronóstico objetivo basados en las interacciones lineales asociados a la persistencia y otro que permita utilizar la información de las interacciones no lineales que se manifiestan en forma de precursores.

En primer lugar, es posible modelar la persistencia como una dependencia inmediata entre un dato con los siguientes suponiendo que estos siguen un modelo de ruido rojo de orden n, por ejemplo, ajustando un modelo autoregresivo de orden n (AR_n). Para esto es posible estimar los coeficientes de acuerdo a los valores “climáticos”, donde no se tienen en cuenta la marcha estacional de la persistencia ni la presencia de precursores. Este modelo, que tiene validez para cualquier día del año puede ser descrito según la ecuación (3.17)

$$T_t = a_0 + a_1T_{t-1} + a_2T_{t-2} + \dots + \varepsilon_t \quad (3.17)$$

	Temperatura máxima				
	30-60	60-90	90-120	120-150	150-180
Campinas					
Tucumán					
Corrientes					
Pergamino					
Pilar					
Buenos Aires					
Santa Rosa					
Río Gallegos					
	Temperatura mínima				
	30-60	60-90	90-120	120-150	150-180
Campinas					
Tucumán					
Corrientes					
Pergamino					
Pilar					
Buenos Aires					
Santa Rosa					
Río Gallegos					

Tabla 3.1. Intervalos de desfases con presencia de correlaciones distantes significativas (gris) por estación

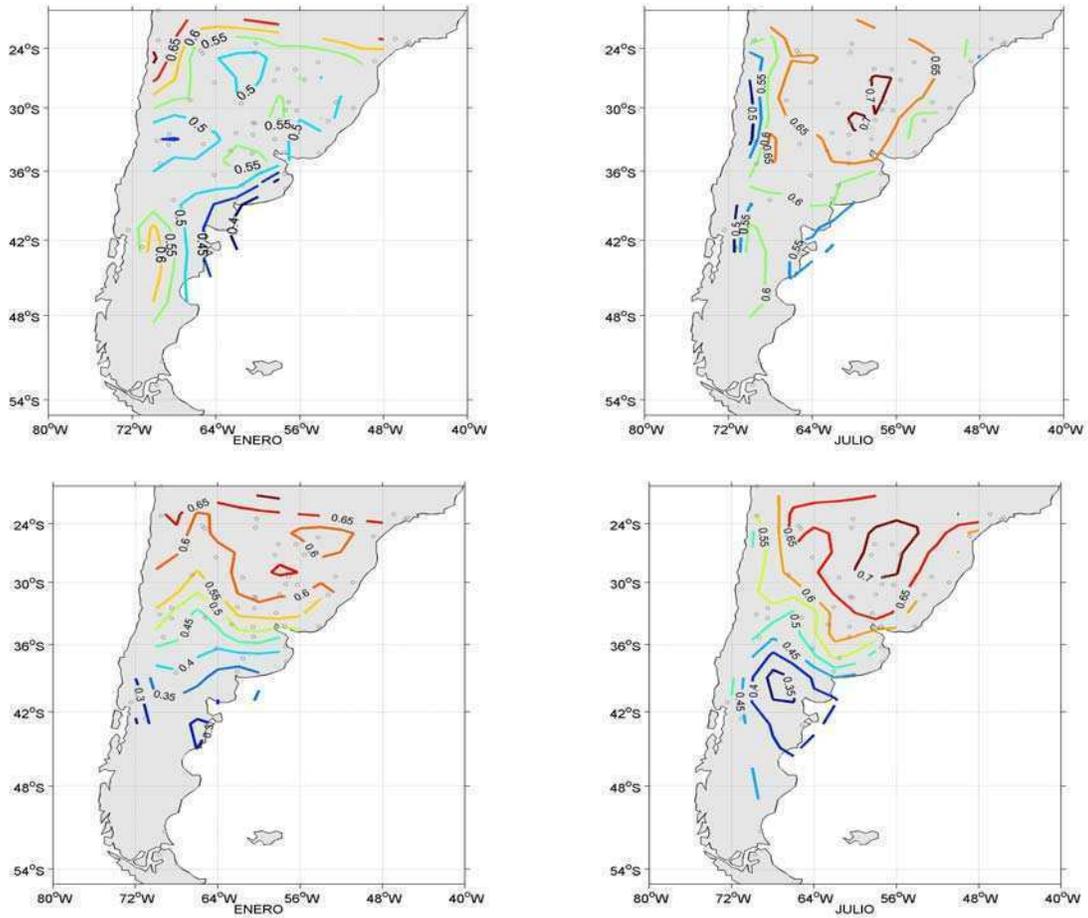


Figura 3.8. Campos medios del primer coeficiente de autocorrelación r_1 sobre la temperatura máxima (superior) y mínima (inferior) para los meses de enero (izquierda) y julio (derecha).

donde T_t es el valor de la anomalía de temperatura en el tiempo t , los coeficientes a_j son constantes asociadas al modelo AR_n y ε_t representa el ruido blanco.

Por otro lado, si se considera la variación estacional e intraestacional de la persistencia y el grado de asociación entre perturbaciones o anomalías distantes, pueden ser representados por un modelo descrito según la ecuación (3.18)

$$T_i = a_0 + a_1 T_{i-1} + a_2 T_{i-2} + \dots + \alpha_1 T_{i1} + \alpha_2 T_{i2} + \dots + \varepsilon_i \quad (3.18)$$

donde T_i es el valor de la anomalía de temperatura para el día i , con $i=1, \dots, 365$ y T_{i1} ó T_{i2} son anomalías distantes de temperatura, los coeficientes a_j están asociados los primeros j lags, donde es considerado el comportamiento estacional de la persistencia, los α_k se los asocia a los desfasajes de orden k (memorias distantes) y ε_i representa el ruido blanco.

3.4 Distribución espacial de la persistencia y memoria lejana del sistema térmico.

Como se mostró anteriormente la estimación de los parámetros que definen a la memoria del sistema es más robusta y estable si se utilizan series de referencia. Por otro, dado que la disponibilidad de estas series temporales en escala diaria es escasa en la región, es de interés conocer la validez regional de los modelos propuestos en la sección anterior.

Con este fin se estiman algunos de los parámetros desarrollados en las secciones anteriores sobre la base de datos que comprende la porción de Sudamérica desde el paralelo S23° hasta el extremo sur del continente. Si bien, en general estas estaciones contienen menos de 45 años de datos diarios (cerca de 16450 valores) es posible obtener una buena distribución espacial de la memoria del sistema para inferir sobre la validez regional de las estaciones de referencia.

En la figura 3.8 se muestran los campos medios del primer coeficiente de autocorrelación, calculado según la ecuación (3.4), para la temperatura máxima y mínima en los meses de enero y julio. En general, para la temperatura máxima se observa una fuerte influencia del efecto marítimo, donde se obtienen valores similares de r_1 (alrededor de 0.45) desde las costas de Río Negro en Argentina hasta el sur de Brasil. Si bien, éste efecto se observa tanto para enero como en julio, la mayor señal se tiene en verano. En esta variable, la persistencia se muestra más homogénea en invierno, donde en toda la parte continental al norte de S36°, se tienen altos valores de r_1 (varían entre 0.65 y 0.7).

Para la temperatura mínima se observa la presencia de un gradiente meridional, más marcado durante el mes de enero, pudiendo destacarse tres regiones con comportamiento homogéneo respecto de la persistencia. La región con mayor persistencia es el área continental que se ubica aproximadamente al norte del paralelo S30° en verano. En invierno

el borde sur de ésta región se desplaza meridionalmente, alcanzando latitudes de hasta S35°.

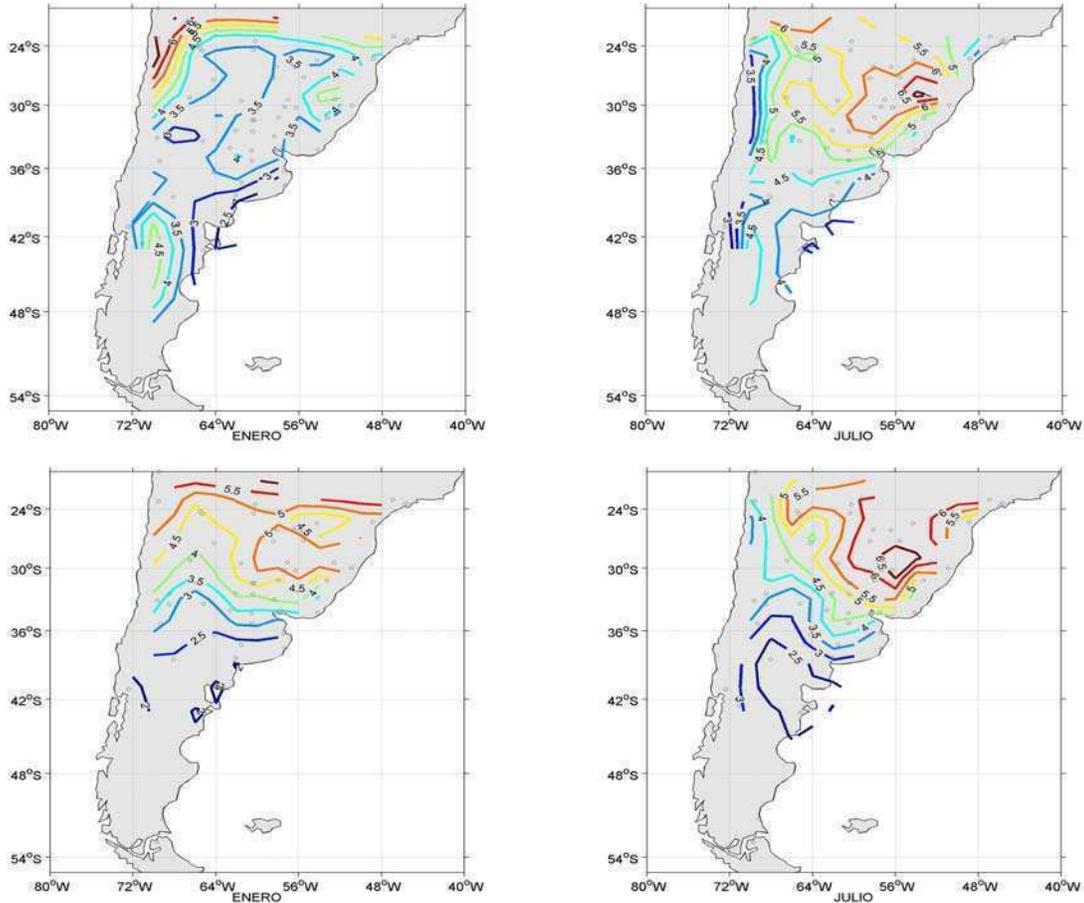


Figura 3.9. Campos medios del tiempo de independencia (T_o) sobre la temperatura máxima (superior) y mínima (inferior) para los meses de enero (izquierda) y julio (derecha).

La segunda región, es una zona de transición, ubicada en el centro de Argentina, donde se observa el mayor gradiente en la persistencia en todo el dominio analizado. Esta zona con alta variación meridional se mantiene prácticamente durante todo el año, aunque en invierno el gradiente se intensifica ya que estas variaciones se producen en un área más reducida. Por último, la Patagonia, región asociada a los procesos de latitudes medias, es la que evidencia relaciones menos persistentes ($r_1 \sim 0.3$).

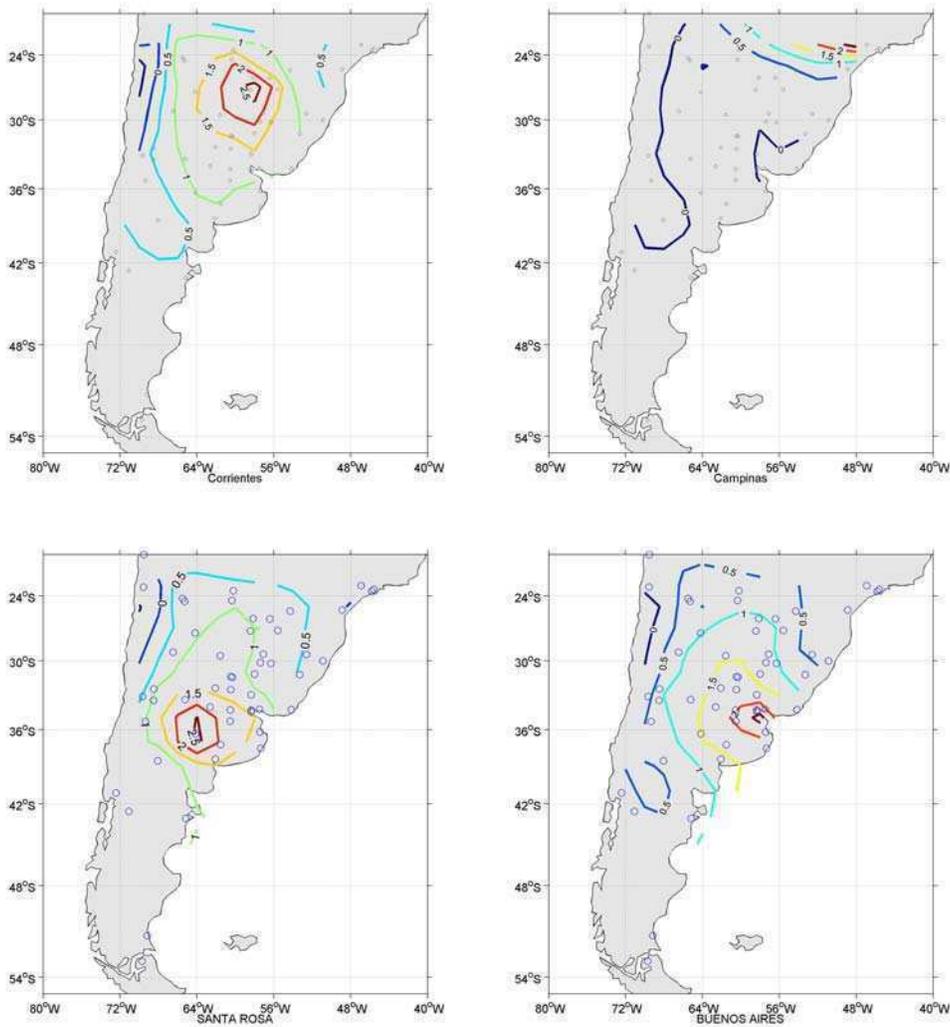


Figura 3.10. Campos de coeficiente de correlación estandarizado para las marchas anuales de r_1 tomando como referencia a Corrientes, Campinas, Santa Rosa y Buenos Aires respectivamente.

Otro parámetro relacionado con la persistencia es el tiempo de independencia entre observaciones (T_0). En la figura 3.9 se muestran los campos medios de T_0 para enero y julio, calculados según la ecuación (3.12). El comportamiento regional es similar al que se observa para el primer coeficiente de autocorrelación. La temperatura máxima evidencia un mínimo en el litoral atlántico con tiempos de independencia que varían entre 2 y 3 días. Los valores más altos de dependencia entre observaciones se observan en el sur de Brasil y

mesopotamia argentina durante el invierno, alcanzando valores entre 5 y 7 días. Sobre la temperatura mínima se manifiesta un gradiente meridional que va desde los mayores valores (entre 6 y 7 días) en las regiones tropicales hasta el mínimo que se observa en el sur del continente (entre 2 y 3 días).

Para medir el grado de representatividad de un modelo que considere la marcha anual de la persistencia, es posible estimar la relación entre cada estación de referencia con la base de datos regional a partir del coeficiente correlación (r). Sin embargo al utilizar esta metodología surgen dos inconvenientes, el primero, dado que el primer coeficiente de autocorrelación de cada día difiere significativamente de cero, es de suponer que la distribución de r no se ajuste a una distribución normal. Dado esto, no es suficiente estimar la desviación estándar de r y utilizarla para medir la exactitud de r como estimador de ρ . Para solucionar este problema es posible aplicar un cambio de variable que transforma la distribución de r en distribución normal. Con este cambio de variable se hace depender Z_r de r , siendo

$$Z_r = \frac{1}{2} \ln \left(\frac{1+r}{1-r} \right) \quad (3.19)$$

Con esto la variable aleatoria Z_r se distribuye aproximadamente normal con media

$$\mu_z = \frac{1}{2} \ln \left(\frac{1+\rho}{1-\rho} \right) \quad (3.20)$$

y desviación estándar

$$\sigma_z = \frac{1}{\sqrt{n-3}} \quad (3.21)$$

Para definir el nivel de confianza con que se desea estimar el error de Z_r , es posible definir el valor crítico para el nivel de confianza α deseado, según:

$$Z_c = \frac{Z_\alpha}{\sqrt{n-3}} \quad (3.22)$$

y

$$Z = \frac{Z_r}{Z_c} \quad (3.23)$$

A partir de la nueva variable Z, es posible comparar valores de correlación para diferentes períodos, ya que se estandariza por el desvío estándar de cada muestra. Más detalles sobre esta estimación se pueden encontrar en Hoel (1976).

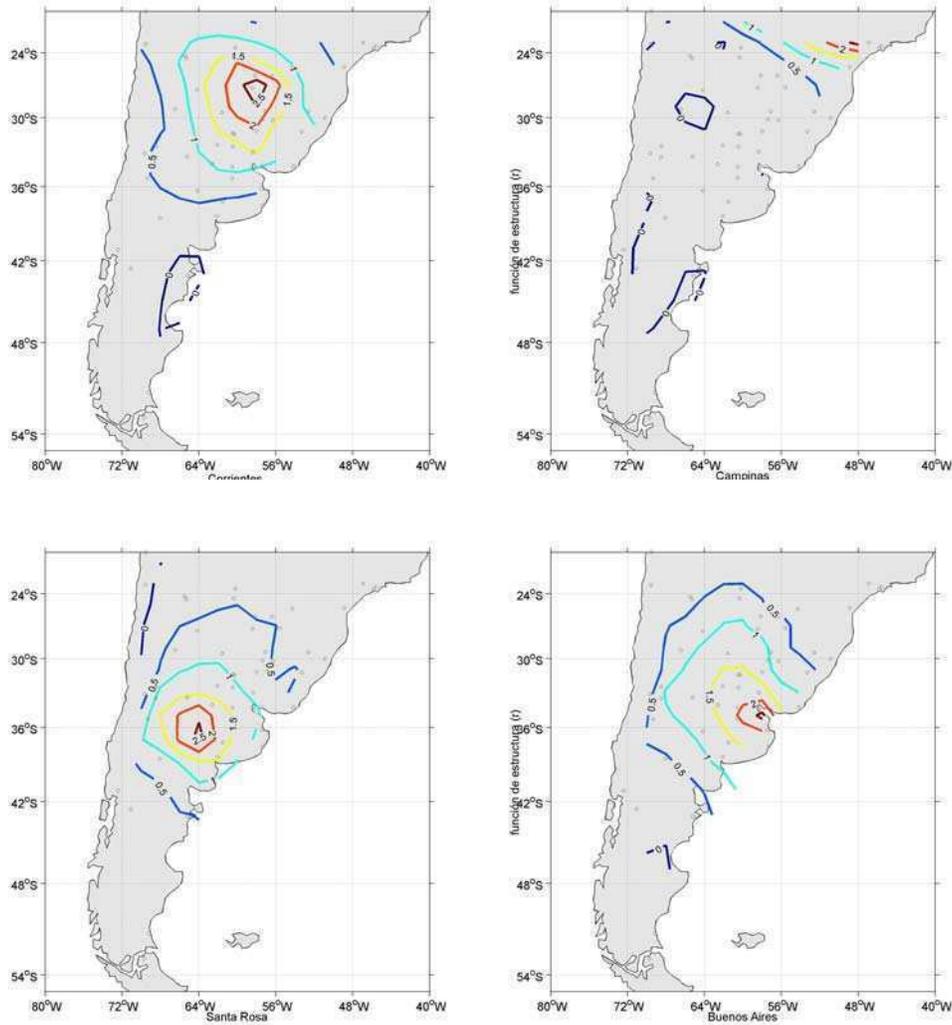


Figura 3.11. Campos de coeficiente de correlación estandarizado para las marchas anuales de r_{30} tomando como referencia a Corrientes, Campinas, Santa Rosa y Buenos Aires.

En la figura 3.10 se muestran los campos de los coeficientes de correlación estandarizados (Z) entre las marchas anuales del primer coeficiente de autocorrelación ($r_{1,i}$), calculados según la ecuación (3.14). Los valores de Z representan el grado de asociación entre las estaciones de referencia (localidades de Corrientes, Campinas, Santa Rosa y Buenos Aires) con la base de datos regional. Las regiones que se encuentren dentro de las isólinea $Z=1$, representan los valores donde la representatividad de la estación de referencia es significativa con un nivel de confianza del 95%. Mientras que si se desean mayores niveles de confianza es posible considerar, por ejemplo, las regiones con valores mayores a 1.5 (~99%) o 2 (~99.9%) desvíos.

Si se considera como limite a los valores de $Z=1$, se observan áreas homogéneas que comprenden a toda la mesopotamia, Uruguay y el norte de la provincia de Buenos Aires, si consideramos como referencia a la localidad de Corrientes, sin embargo si consideramos el limite de $Z=1.5$ la influencia se restringe solo al noreste Argentino. Si se analiza el área representativa de Santa Rosa, considerando el nivel de 99%, se observa que ésta representa la porción de Argentina Central, en particular a la Pampa seca, donde la asociación con las estaciones costeras de la provincia de Buenos Aires es solo significativa al 95%. Buenos Aires, representa en mejor medida el comportamiento de la marcha anual de la persistencia de la Pampa húmeda (área encerrada dentro de las isólineas de $Z=1.5$), aunque si se considera un menor nivel de confianza, la influencia de ésta estación de referencia se extiende hacia el norte.

Finalmente, Campinas, tiene un comportamiento asociado a la frontera noreste del dominio analizado en este trabajo. Esta estación solo representa lo que ocurre al norte de $S24^\circ$, porción que no se puede asociar a la otra estación de referencia más cercana (Corrientes). Por este motivo es necesario considerar esta localidad para caracterizar el comportamiento de la persistencia en el norte de la Cuenca del Plata.

Si se considera la representatividad de las memorias lejanas, en la figura 3.11 se muestra el mismo análisis realizado en la figura 3.10, pero para la marcha anual de la relación entre el día i con el día $i+30$ ($r_{30,i}$ según ecuación 3.14). En general, las regiones de representatividad de las estaciones de referencia son similares a lo discutido para la marcha estacional de la persistencia, pero con un menor radio de influencia.

Para estudiar el grado de coherencia espacial de la persistencia, es posible analizar la función de correlación espacial o función de estructura (Gandin, 1970). Esta función describe la relación entre los coeficientes de correlación la marcha anual de la persistencia en varios puntos en un área relativamente uniforme, con la distancia entre estos puntos. Para definir esta función de estructura, supongamos que para la variable f,

$$f'(x, y) = f(x, y) - \bar{f}(x, y) \quad (3.24)$$

se tiene que la ecuación (3.24) expresa la anomalía de f respecto del valor medio en el punto con coordenadas x,y. Mientras que se define a

$$D_f(x, y) = \overline{f'^2}(x, y) \quad (3.25)$$

como la varianza del elemento f en el punto analizado.

Ahora, si consideramos dos funciones, donde cada una depende en general de cuatro variables independientes (x_1, y_1, x_2, y_2) y si la variable f cumple con las condiciones de homogeneidad e isotropía es posible asumir que el grado de relación entre distintos puntos solo dependa de la distancia entre estos. Cabe considerar que a nivel de superficie, las características del relieve tienen una influencia significativa en el cumplimiento de estas condiciones. En regiones montañosas se asume que las condiciones de homogeneidad e isotropía no se cumplen. En la práctica solo se puede decir que la homogeneidad e isotropía son condiciones solo aplicables en áreas llanas con una relativamente homogénea superficie. Según estas consideraciones se puede definir a la función de estructura entre los puntos x_1, y_1 y x_2, y_2 como

$$\mu_f(x_1, y_1, x_2, y_2) = \frac{\overline{f'(x_1, y_1)f'(x_2, y_2)}}{\sqrt{D_f(x_1, y_1)D_f(x_2, y_2)}} \quad (3.26)$$

Con estos elementos, es posible estudiar el radio de influencia evaluando la función de estructura sobre las marchas anuales de la persistencia y memorias lejanas. Básicamente, ésta función relaciona el nivel de asociación entre una variable (en éste caso la persistencia y precursores) en una localidad con la misma información en distintas ubicaciones, es decir

se tiene el nivel de asociación entre estaciones en función de la distancia. En la figura 3.12 se muestran las funciones de estructura, para las marchas estacionales de $r_{1,i}$, $r_{30,i}$, $r_{45,i}$ y $r_{60,i}$. En general, tanto para la persistencia como para las asociaciones lejanas se observa un radio de influencia de entre 500 y 1000 Km. Aunque si bien, la influencia decrece para las asociaciones entre observaciones mayores a 45 días (aproximadamente a 500 Km), estas siguen siendo de gran escala, con lo cual es posible inferir sobre la naturaleza de los procesos físicos que conforman memorias lejanas dentro de las series temporales de temperatura. En este sentido, Minetti, (1991) muestra que las singularidades climáticas intraestacionales se pueden deber al comportamiento altamente recurrente de definidos tipos de circulación.

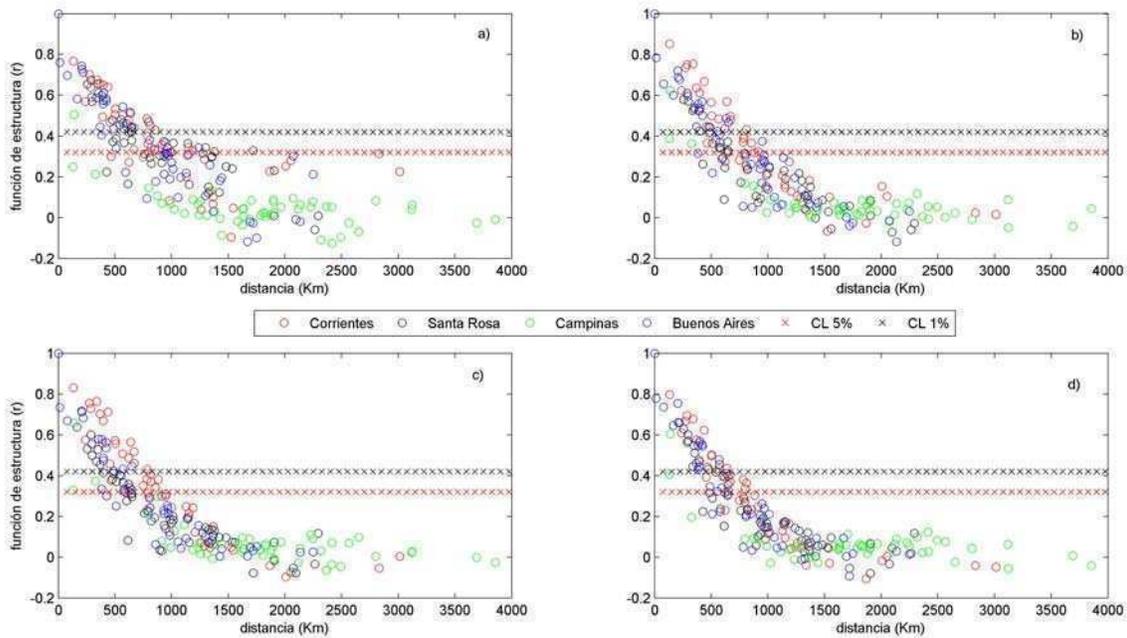


Figura 3.12. Función de estructura para la marcha anual de r_1 (a), r_{30} (b), r_{45} (c) y r_{60} (d).

Otra pregunta que surge sobre el aspecto regional de los precursores, es sobre si existe una estacionalidad definida en la ocurrencia de estos. En la figura 3.13 se muestran los campos asociados a la magnitud y fecha de ocurrencia de las marchas anuales de $r_{45,i}$ y $r_{60,i}$ con $i=1, \dots, 365$ sobre la temperatura mínima. Estos valores fueron obtenidos a partir de las series suavizadas con promedios móviles, ya que se desea representar la estacionalidad regional más que efectos peculiares producto de la inestabilidad de la estimación asociada a

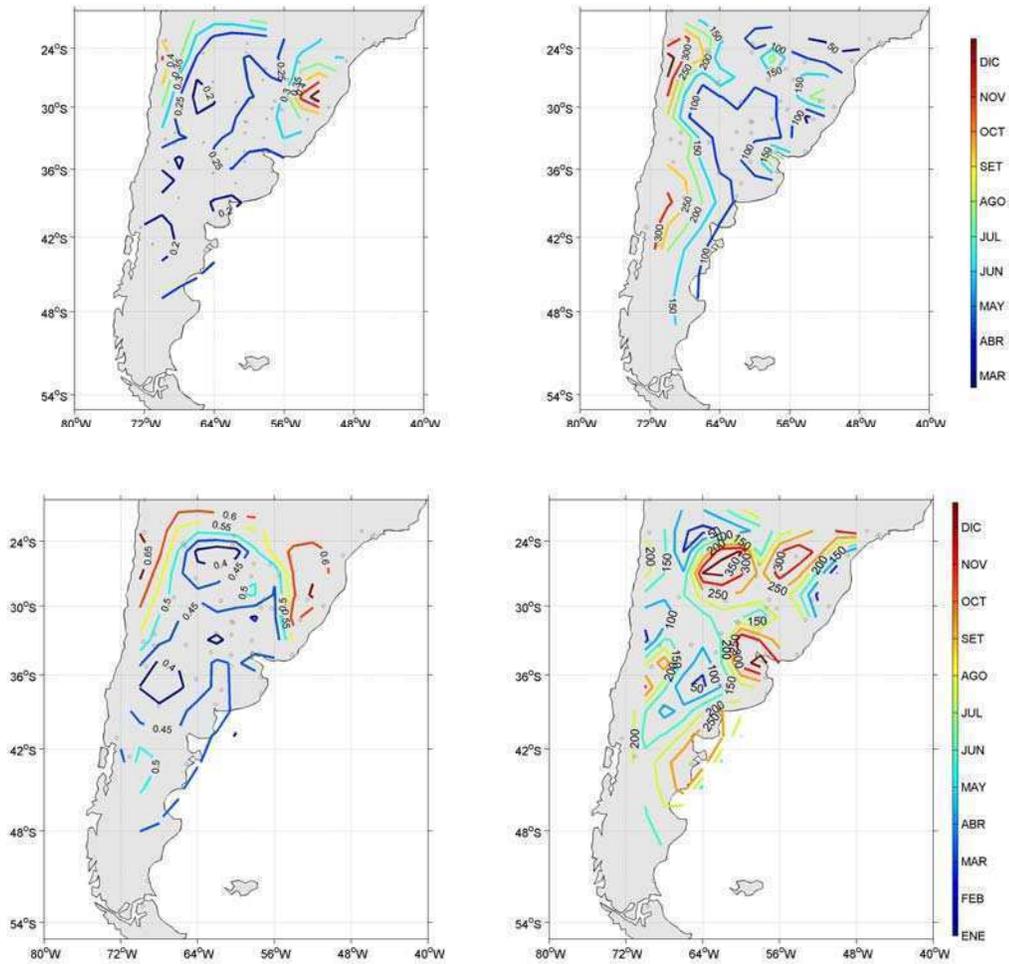


Figura 3.13. Campos del coeficiente de autocorrelacion máximo (izquierda) y fecha de ocurrencia (derecha) para lag k=45 (arriba) y para el lag k=60 días (abajo).

la longitud de períodos de la base de datos regional. Comparando estos dos desfases, se observa la mayor señal en los cuasi-ciclos asociados a 60 días. Para 45 días se observan las mayores asociaciones en este período en el estado de Paraná, Brasil y en el norte de Chile. En general periodicidades de este tipo se dan preferentemente entre los meses de abril y junio en casi toda la región, solo con la excepción del área andina donde el máximo de asociaciones tiende a observarse en primavera.

Por otro lado, para desfases de 60 días se observa en general una mayor señal, donde las asociaciones son significativas en casi toda la región con valores de máximos de $r_{60,i}$ entre

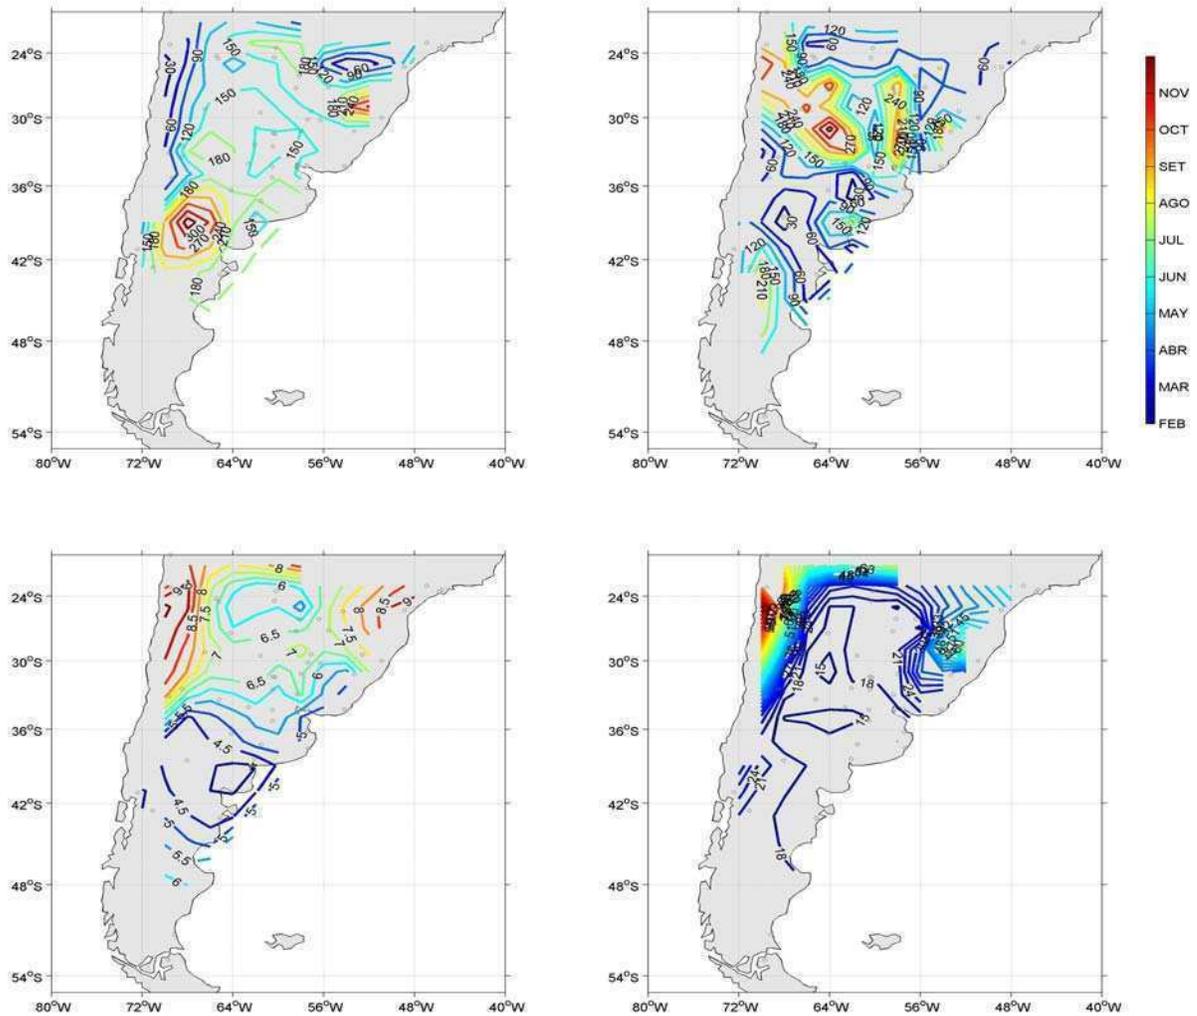


Figura 3.14. Distribución espacial de fecha de ocurrencia (arriba) y la cantidad de r_k significativos (abajo) entre 1 y 10 días (izq) y entre 11 y 180 días (derecha).

0.4 y 0.6, todos significativos al 95%, hasta para las estaciones con períodos más cortos. En cuanto a la estacionalidad de estas periodicidades, se pueden destacar tres regiones que se distinguen por su orientación meridional. Una región costera que comprende el litoral atlántico desde la Patagonia hasta Brasil, donde también se incluye el noreste Argentino, que muestra la presencia de éstas asociaciones entre fines del invierno y la primavera, una región en el centro del continente donde los máximos tienden a ocurrir en otoño y en la costa pacífica donde la ocurrencia es preferente en invierno.

Para generalizar éste análisis, se propone estudiar la distribución espacial sobre los días que poseen una mayor persistencia (o días correlacionados significativamente sin que las dependencias se interrumpan) y sobre los días que presentan mayor cantidad de asociaciones distantes significativas. En la figura 3.14 se muestran las distribuciones espaciales de las fechas de ocurrencia (i) con mayor cantidad de $r_{k,i}$ significativos entre 1 y 10 días (persistencia) y entre 11 y 180 días (precursores).

Si consideramos a la persistencia, en toda la región al norte del paralelo S36° se observa la mayor dependencia para los meses de otoño y comienzo del invierno, siendo estos valores de dependencia entre 4 y 7 días en concordancia con lo mostrado en la figura 3.3. Al sur de este dominio y en la porción continental se observan que los días más persistentes se dan en primavera. Esto no ocurre en la costa atlántica de la Patagonia donde los días con mayor cantidad de memorias significativas se deben buscar entre fines de otoño y comienzo del invierno. Para los precursores (asociaciones significativas del día i con el día i+11 hasta el día i+180) se tiene que existe una mayor tendencia a la presencia de memoria distantes en las series de temperatura entre invierno y primavera en el norte y centro de Argentina y sur de Brasil con entre 15 y 20 asociaciones distantes significativas por día del año. Así mismo, la Patagonia muestra un comportamiento diferenciado donde la mayor preferencia es en otoño.

3.5 Variabilidad de baja frecuencia de la persistencia

En la sección anterior se mostró que existen cambios estacionales y espaciales en la persistencia, definida ésta por el primer coeficiente de la función de autocorrelación. Ahora se desea establecer si además existe una variabilidad interanual definida que pueda producir cambios en la estimación de los modelos de diagnóstico y pronóstico objetivo. Como se mostró al inicio de éste capítulo, es posible estimar la función de autocorrelación para distintas submuestras de una serie temporal de distintas maneras (ver ecuaciones de (3.5) a (3.12)). En particular se consideró cada submuestra conformada por la información diaria de cada año del registro.

Como se mostró anteriormente, la principal diferencia entre las dos estimaciones es el uso de las medias de cada muestra (ecuación 3.5), que permite comparar la variabilidad interna

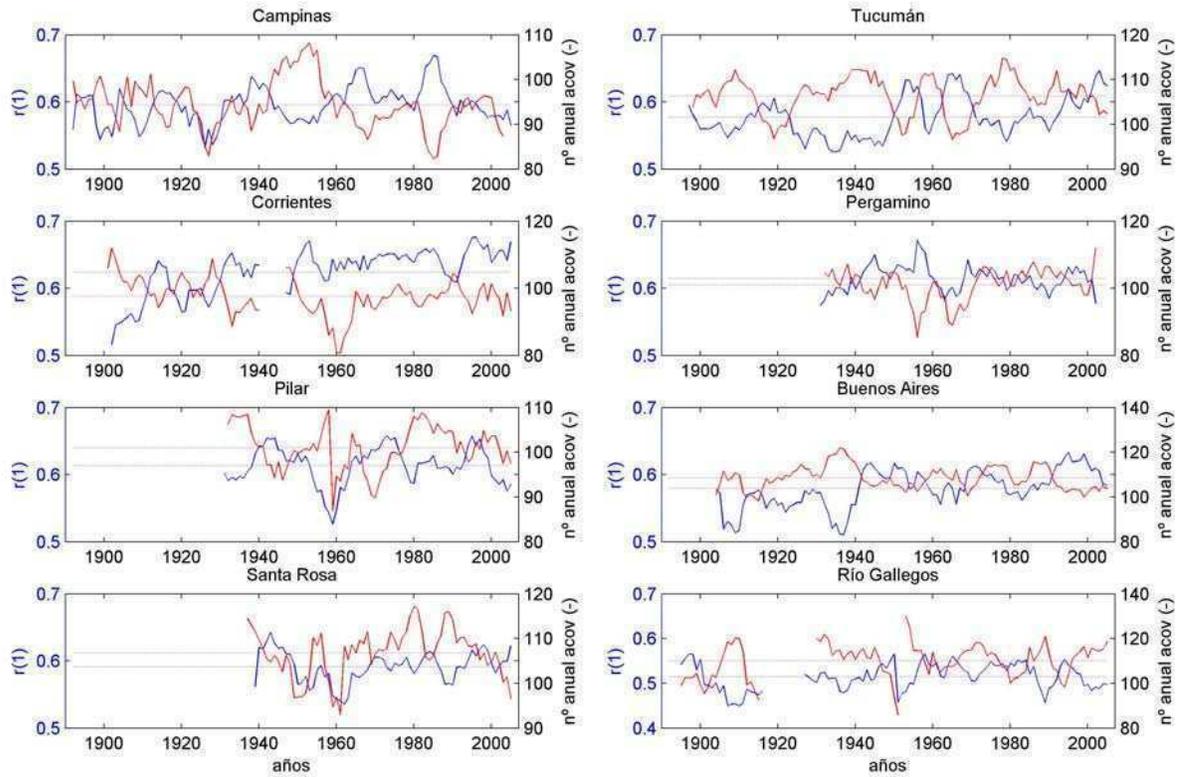


Figura 3.15. Marcha interanual del primer coeficiente de autocorrelación calculado según ecuación (3.7) (azul), y valor medio (ec. (3.8)) (azul en línea de puntos) y frecuencia anual de autocovarianzas negativas para el lag 1 (antipersistencia) en rojo para la temperatura máxima en las estaciones de referencia.

de la persistencia y asociaciones lejanas de cada año. Por otro lado, si se calcula la función de autocorrelación utilizando la media y varianza total (ecuación 3.9) de la muestra, es posible estimar si existen cambios de largo plazo, ya que se compara la persistencia de cada año respecto de un origen común.

Siguiendo la misma línea de razonamiento y dado que el primer coeficiente de autocorrelación de cada año representa la persistencia, es posible definir como primer aproximación a la antipersistencia como a la cantidad anual de los términos de autocovarianzas entre el día i con el $i+1$ que tienen signo negativo. Esto implica, que un año con mayor cantidad de autocovarianzas negativas está relacionado con una mayor

cantidad de transiciones, es decir hay un mayor paso de anomalías negativas a positivas o viceversa.

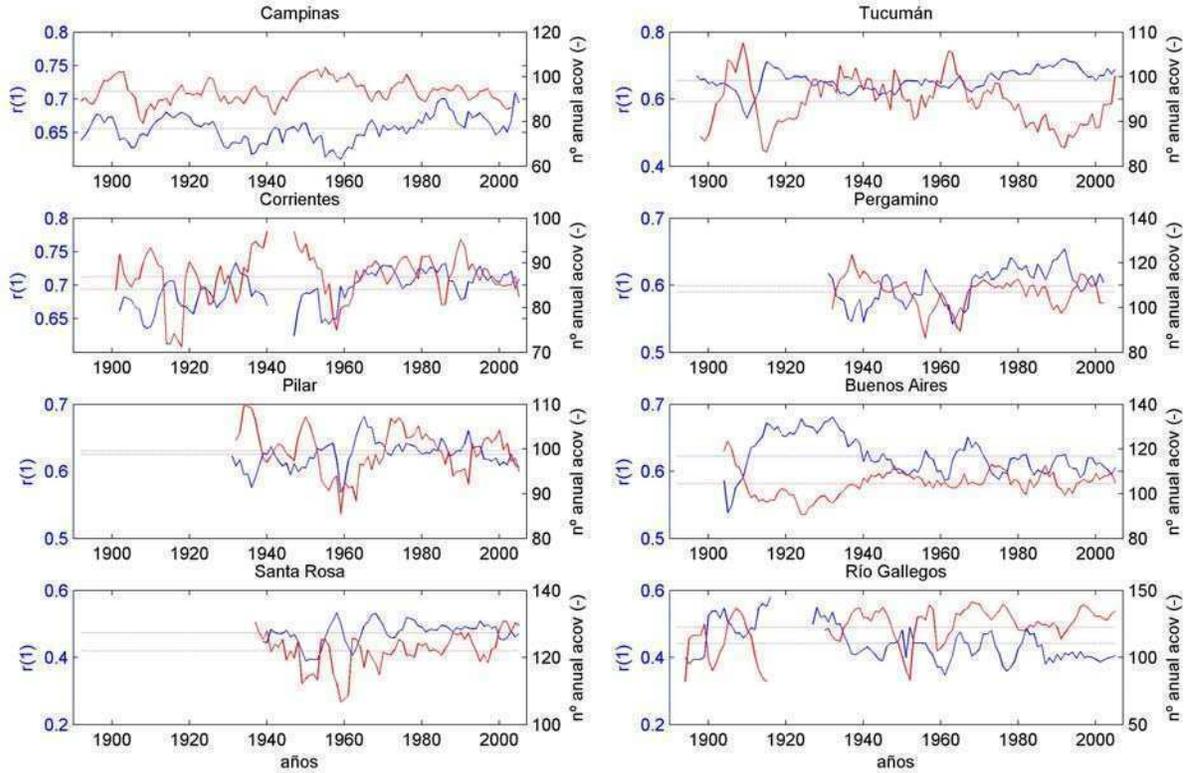


Figura 3.16. Marcha interanual del primer coeficiente de autocorrelación calculado según ecuación (3.7) (azul), y valor medio (ec. (3.8)) (azul en línea de puntos) y frecuencia anual de autocovarianzas negativas para el lag 1 (antipersistencia) en rojo para la temperatura mínima en las estaciones de referencia.

En las figuras 3.15 y 3.16 se muestran las marchas interanuales de r_1 y frecuencia anual de autocovarianzas negativas estimadas según la ecuación (3.7), es decir cada autocovarianza es calculada respecto de los valores medios y varianzas de cada año. En general se observa que para los años con mayor/menor persistencia hay una menor/mayor cantidad de términos de la autocovarianza negativos. A partir de esto se puede caracterizar los años dominados por fenómenos más persistentes están asociados directamente a una disminución en la cantidad de cambios de estados. Sin embargo, a pesar de ser esto cierto, también se observan algunos años donde hay una relación directa entre el primer coeficiente de

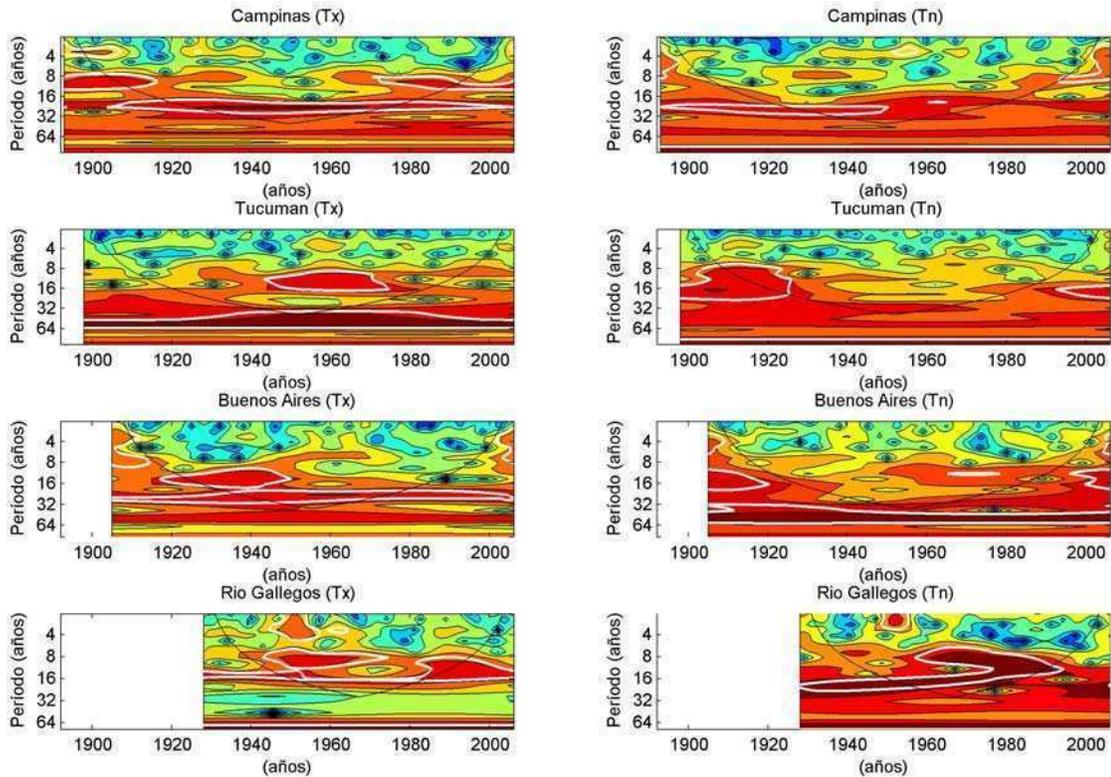


Figura 3.17. Espectro Wavelet estimado en base a las marchas interanuales del primer coeficiente de autocorrelación calculado según ecuación (3.7) (azul), y valor medio (ec. (3.8)). Los contornos blancos representan el nivel de significancia del 5%, respecto de un modelo autoregresivo.

autocorrelación y la frecuencia anual de autocovarianzas. Esto implica que, por ejemplo un año se puede definir como altamente persistente con gran cantidad de cambios estados, pero existen algunos casos de eventos cálidos o fríos extremos (es indistinto, en ambos casos se tienen valores positivos de las contribuciones de la autocovarianza), que por su magnitud y persistencia influyen directamente la estimación del primer coeficiente de autocorrelación.

Si analizamos la variabilidad de baja frecuencia de estas series, en la figura 3.17 se muestra el espectro Wavelet donde se muestra la densidad espectral asociada a las marchas de r_1 en función del tiempo para Campinas, Tucumán, Buenos Aires y Río Gallegos. En general se

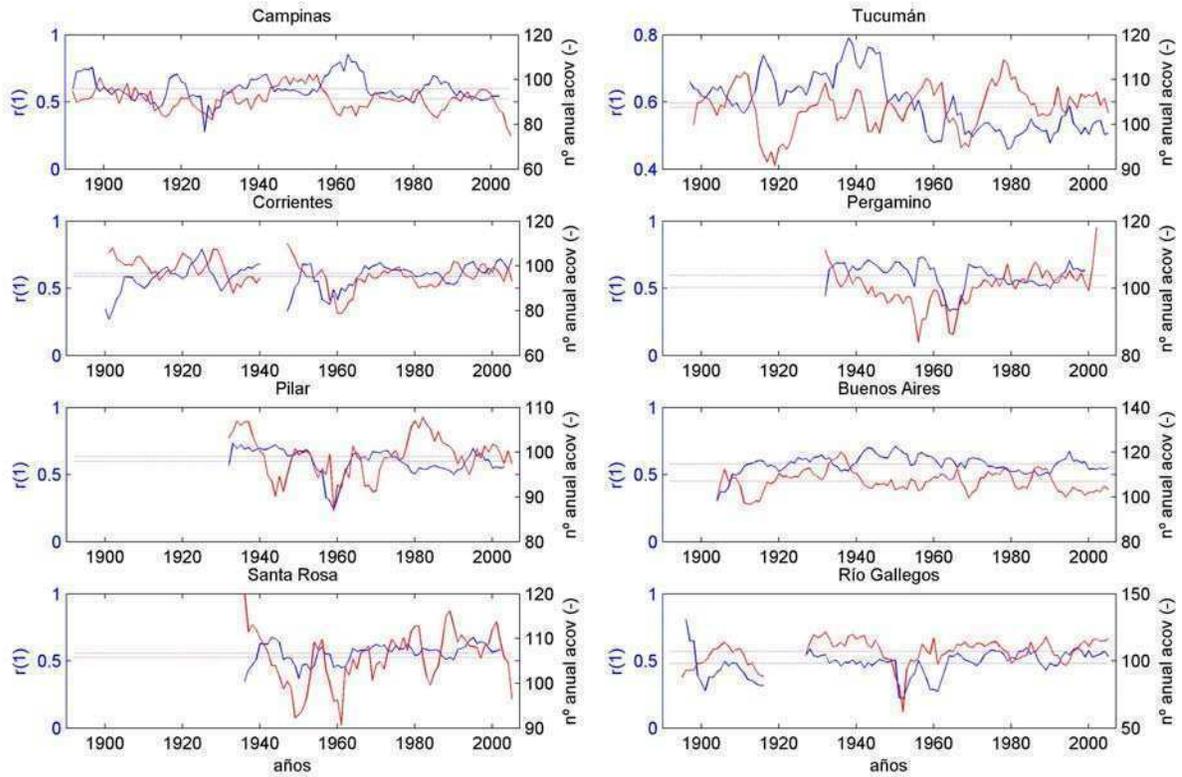


Figura 3.18. Marcha interanual del primer coeficiente de autocorrelación calculado según ecuación (3.11) (azul), y valor medio (ec. 3.12) (azul en línea de puntos) y frecuencia anual de autocovarianzas negativas para el lag 1 (antipersistencia) en rojo para la temperatura máxima en las estaciones de referencia.

observa que para todas las estaciones existen oscilaciones de períodos entre 18 y 25 años, aunque estas periodicidades presentan cambios con el tiempo. Principalmente, el mayor cambio de la variabilidad regional se observa entre los años 1950-1970, salvo en Río Gallegos donde se observa una periodicidad de aproximadamente 18 años durante todo el registro. Estos cambios de baja frecuencia concuerdan con los resultados obtenidos en distintas variables del sistema climático por Compagnucci y Vargas (1983), Minetti (1989), Minetti y Carletto (1990) y Vargas et al (2002), donde encuentran señales con períodos entre 17 y 26 años.

En las figuras 3.18 y 3.19 se analizan las marchas interanuales de r_1 y frecuencia anual de autocovarianzas negativas estimadas según la ecuación (3.9). En este caso cada

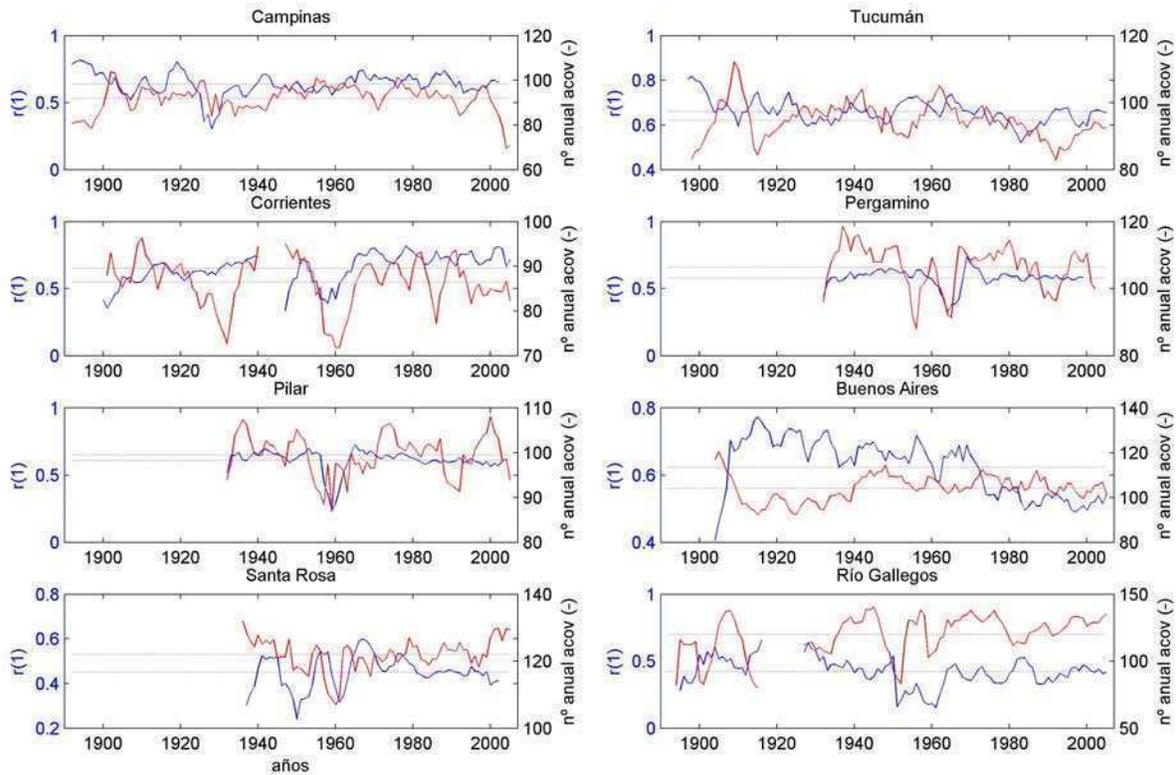


Figura 3.19. Marcha interanual del primer coeficiente de autocorrelación calculado según ecuación (3.11) (azul), y valor medio (ec. (3.12)) (azul en línea de puntos) y frecuencia anual de autocovarianzas negativas para el lag 1 (antipersistencia) en rojo para la temperatura mínima en las estaciones de referencia.

autocovarianza es calculada respecto de los valores medios y varianzas de toda la muestra. Dado que cada año es comparado con los mismos parámetros muestrales, esta estimación provee un sistema de referencia fijo, que permite analizar los cambios en el largo plazo. En estas representaciones se observa que los mayores cambios se observan al igual que en el caso anterior entre los años 1950-1970, en algunos casos con un aumento de la variabilidad y en otros en la forma de saltos o cambios abruptos. Esto también se puede observar en el análisis espectral Wavelet (figura 3.20) donde se observa en este período en particular la aparición de oscilaciones de distintas frecuencias (entre 8 y 16 años).

Estos cambios analizados en la persistencia evidencian probablemente la variación en la frecuencia de distintos tipos de circulación que tienen un impacto directo en la estructura

térmica regional. Así mismo, variaciones de este tipo pueden tener serios impactos socio-económicos ya que estos afectarían directamente la frecuencia y duración de los eventos extremos. Por esto el seguimiento o monitoreo de los cambios de estado en escala intraanual de las variables que definen tanto a la persistencia como a la antipersistencia se vuelve una herramienta necesaria a la hora de decidir sobre la validez y comprensión de las características generales del modelo de pronóstico objetivo a utilizar.

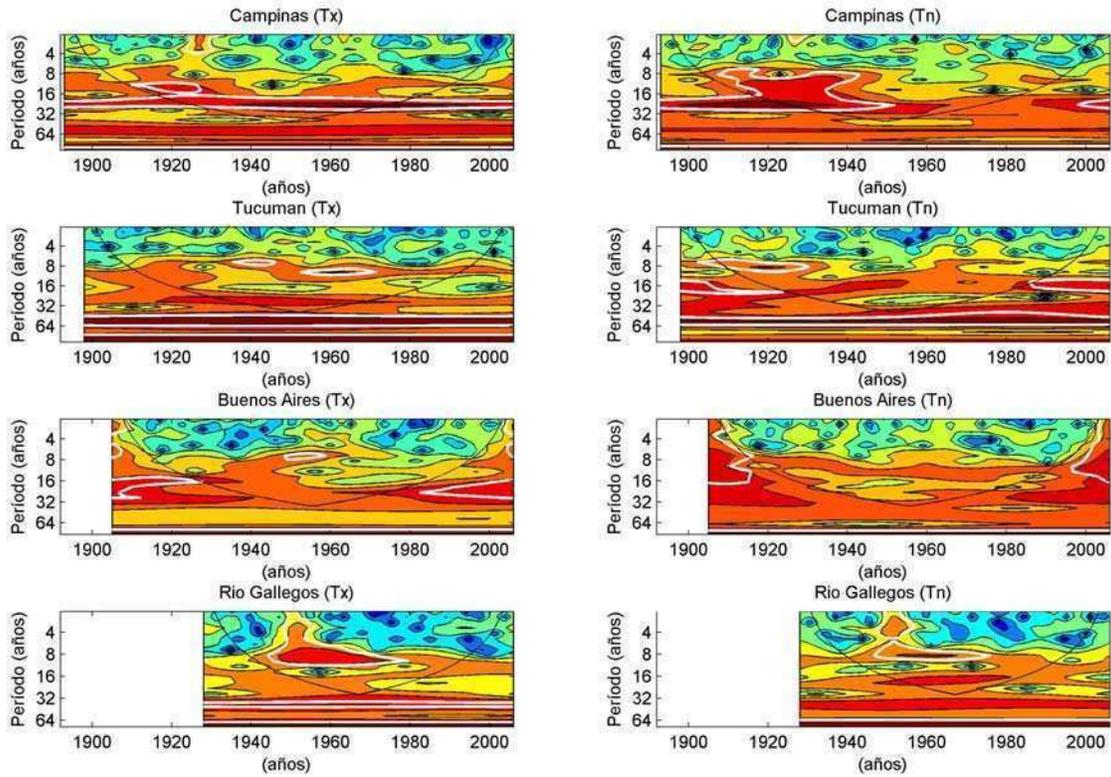


Figura 3.20. Espectro Wavelet estimado en base a las marchas interanuales del primer coeficiente de autocorrelación calculado según ecuación (3.11) (azul), y valor medio (ec. 3.12). Los contornos blancos representan el nivel de significancia del 5%, respecto de un modelo autoregresivo.

CAPITULO 4

PREDICTABILIDAD Y TEORIA DE LA INFORMACION

El estado del sistema climático es especificado por un conjunto finito de números, denominado “vector de estado” (x_t), el cual evoluciona de acuerdo a un conjunto de ecuaciones conocidas. Aunque el modelo que describe la evolución del sistema es conocido, el estado puede ser incierto por errores en las observaciones o también por que el modelo contiene términos que varían aleatoriamente (DelSole and Tippet, 2007). Así, la más completa descripción del sistema y sus incertezas se puede lograr a través de su función de distribución de probabilidades (PDF). Esta distribución se puede interpretar como la densidad de posibles estados. Por esto, como cada estado evoluciona de acuerdo con las ecuaciones que gobiernan el sistema, también cambian las PDF que describen la densidad de estados (Lorenz 1963).

Si las ecuaciones que gobiernan el sistema contienen procesos aleatorios de alguna clase, para que ocurra lo mencionado en el párrafo anterior, el sistema debe satisfacer las propiedades de Markov. Esto significa que dado un estado x_t para el tiempo t , se mantiene inalterada la probabilidad condicional de un estado futuro en el tiempo $t+\tau$, aunque se introduzca información de tiempos anteriores a t . La distribución de estados futuros $x_{t+\tau}$ se denota $p(x_{t+\tau}|x_t)$ y usualmente se denomina como probabilidad de transición (Wilks, 2002). Estas probabilidades de transición se pueden calcular a partir de un modelo determinístico o estocástico y describen completamente la evolución de los procesos markovianos.

Las probabilidades de transición también implican un grado específico de correlación serial o persistencia. Supongamos una serie temporal binaria, por ejemplo el primer estado es el contiene todas las anomalías de temperatura negativas (estado 0) mientras que el segundo es el que representa valores de anomalías superiores a cero (estado 1). Por lo tanto las probabilidades de transición se pueden definir como:

$$p_{00} = \Pr\{x_{t+1} = 0 | x_t = 0\} \quad (4.1)$$

$$p_{01} = \Pr\{x_{t+1} = 1 | x_t = 0\} \quad (4.2)$$

$$p_{10} = \Pr\{x_{t+1} = 0 | x_t = 1\} \quad (4.3)$$

$$p_{11} = \Pr\{x_{t+1} = 1 | x_t = 1\} \quad (4.4)$$

En conjunto, las ecuaciones (4.1) y (4.2) constituyen la distribución de probabilidad condicional para el valor de la serie temporal en el tiempo $t+1$ determinado por el $x_t=0$ en el tiempo t . Del mismo modo las ecuaciones (4.3) y (4.4) expresan la distribución de probabilidades condicionales para el próximo valor de la serie temporal considerando que el valor actual es $x_t=1$.

Con esto es posible escribir el primer coeficiente de autocorrelación ($\text{lag}=1$) en términos de las probabilidades de transición (Wilks, 2002);

$$r_1 = p_{11} - p_{01} \quad (4.5)$$

En el contexto de una cadena de Markov, r_1 es conocido usualmente como el parámetro que define la persistencia (ver capítulo 2). Por esto, mientras el coeficiente r_1 crece, la diferencia entre p_{11} y p_{01} crece, es decir es mucho más probable que el estado 1 sea seguido por el mismo estado y menos probable que evolucione al estado 0. Esto significa que existe una tendencia de que los estados 0 y 1 se agrupan en intervalos de tiempo, es decir tienden a ocurrir en secuencias o n-tuplas. Por otro lado, para una serie temporal que no presenta autocorrelación puede ser caracterizada por $r_1=p_{11}-p_{01}=0$. En este caso las dos distribuciones de probabilidades condicionales son iguales y la serie es simplemente un conjunto de realizaciones independientes.

Así mismo, la PDF condicional que describe el estado del sistema y por lo tanto su predictabilidad cambia discontinuamente luego de que el sistema sea observado. Por ejemplo, un 10% de chance de que la temperatura exceda un cierto umbral instantáneamente puede cambiar a un 100% de certeza luego de que la temperatura fuese observada.

Por esto, el carácter de la dinámica del sistema, lineal o no lineal y la precisión de las observaciones de los estados iniciales deciden sobre el horizonte de la predictabilidad. Para los sistemas más complejos, como los asociados a procesos climáticos o económicos, se tiene en general poco conocimiento acerca de su predictabilidad (Feistel, Ebeling (1989) y Ebeling, (2002)). El principal tema que se discute en este capítulo es acerca del comportamiento espacial y temporal acerca de las chances de predecir estados térmicos futuros a través de la persistencia.

Una herramienta básica para responder a estas preguntas es la teoría de la información a través de la entropía condicional introducida por Shannon (ver Shannon 1948 y 1950) y utilizada por muchos investigadores como Leung and North (1990), Ebeling (1997), Werner et al (1999), Molgedey y Ebeling: (2000), Roulston and Smith (2002), Balling and Roy (2004), DelSole and Tippett (2007), Tang et al (2008) y Naumann and Vargas (2009).

4.1 Definición de Entropía

Supongamos, nuevamente que es posible tratar al problema de la evolución de la temperatura considerando solamente dos estados, es decir valores diarios por encima y por debajo de la marcha estacional. Para el día t existe una incerteza acerca de cual estado térmico tendrá el aire en superficie en el día $t+1$. La ocurrencia de eventos dicotómicos que evolucionan estocásticamente contiene 1 bit de información. En general, una variable que puede alcanzar N posibles estados contiene $\log_2(N)$ bits de información. Por esto, a mayor numero de posibles estados, mayor es la incerteza, la que se refleja en un mayor grado de información.

Sin embargo, si existe algún grado de conocimiento del sistema (sobre los posibles valores que tomara en el dia $t+\tau$), la cantidad de información se reduce proporcionalmente al nivel de este conocimiento. Ahora supongamos una variable del sistema climático que puede alcanzar ocho posibles estados, pero se conoce que para una determinada región o intervalo de tiempo que estos estados son imposibles. El conocimiento de que en algunos casos ciertos eventos son imposibles reduce la incerteza que existe sobre el sistema, dejando en este caso solo dos posibles estados térmicos. Por lo tanto, a través de la sustracción de información entre las condiciones iniciales de conocimiento del sistema respecto de las actuales se obtiene en este caso $\log_2(8) - \log_2(2)=2$ bits de información.

Extendiendo este razonamiento, se observa que a un mayor conocimiento acerca de los posibles estados que puede alcanzar el sistema menor es el riesgo de hacer una predicción errónea.

$$\log_2(N_{inicial}) - \log_2(N_{actual}) = \log_2\left(\frac{N_{inicial}}{N_{actual}}\right) = -\log_2\left(\frac{N_{actual}}{N_{inicial}}\right) = -\log_2(P) \quad (4.6)$$

donde P es la probabilidad de acierto.

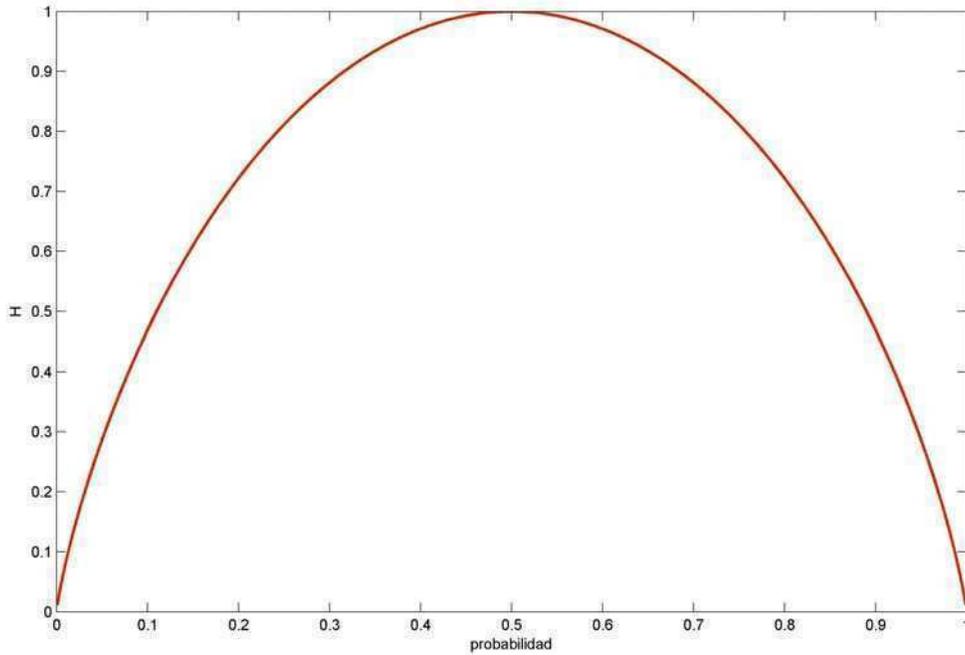


Figura 4.1. Entropía (H) en función de la probabilidad de $x=1$ considerando un sistema que solo puede alcanzar dos estados ($x=0$ y $x=1$).

A partir de esto es posible definir la entropía (H) de acuerdo a Shannon, (1948 y 1950), cuyo nombre es explicado por la similitud con la entropía de Boltzmann relacionada con la física estadística. El parámetro H es una cantidad fundamental en la aplicación de la teoría de la información a sistemas dinámicos y series temporales. Supongamos que x es una variable discreta que puede tomar $i=1 \dots m$ valores posibles (símbolos), entonces

$$H(x) = -\sum_{x=i}^m p_i(x) \log_2(p_i(x)) \quad (4.7)$$

De la ecuación (4.7) se puede deducir que la mayor incerteza de una fuente de información se tiene cuando todos los símbolos de salida de la fuente tienen la misma probabilidad. En la figura 4.1 se muestra la entropía (H) en función de la probabilidad de que $x=1$ para eventos dicotómicos [$\Pr(x=0) = 1 - \Pr(x=1)$]. Aquí se observa que la menor entropía ($H=0$) se tiene cuando alguno de los dos estados ocurre de manera determinística [$\Pr(x=1) = 1$ ó $\Pr(x=0)=1$]. Por otro lado, cuando todos los resultados son igualmente probables la incerteza del sistema aumenta, con lo cual los eventos son pocos predecibles y la entropía alcanza su máximo valor ($H=1$).

Ahora, si se consideran m estados, la entropía varía de 0 hasta $\log(m)$, con lo cual la entropía se puede estandarizar para que sus valores varíen entre 0 y 1, calculando el cociente entre la entropía observada y su máximo (se obtiene al considerar que los m estados son equiprobables).

4.1.1 Entropía de una secuencia de estados

A partir del concepto de entropía es posible detallar aspectos cuantitativos sobre la predictabilidad. Para esto, en el caso de una variable continua como la temperatura es necesario discretizar sus series temporales. A partir de este procedimiento se obtienen secuencias de longitud N de los diferentes estados térmicos caracterizados por m diferentes símbolos $A = \{A_1, A_2, \dots, A_m\}$. La construcción de estas secuencias a partir de series temporales bi-dimensionales se detalla en la sección 4.2. Una vez obtenida una discretización de la información es necesario conocer la incerteza de predecir un estado dentro de una secuencia de datos y como cambia la predictabilidad luego de que se introduce información de estados pasados.

El estudio de las secuencias de estados se basa en la posibilidad de tomar más de un estado y su probabilidad de ocurrencia a lo largo de una secuencia de n -días. Para esto, es posible tomar un bloque de n -días y calcular la probabilidad de encontrar cada estado en esta secuencia. Esta probabilidad (p_i^n) puede ser calculada estimando la frecuencia relativa de ocurrencia del bloque i respecto de los $N-n+1$ bloques en la secuencia. Por lo tanto la entropía H_n de una secuencia depende del tamaño del bloque y se calcula según la ecuación (4.8);

$$H_n = -\frac{1}{\log(m)} \sum_{x=i}^m p_i^n \log(p_i^n) = -\sum_{x=i}^m p_i^n \log_m(p_i^n) \quad (4.8)$$

Las dos expresiones de la derecha son equivalentes y refiere a la entropía H_1 normalizada en 1, dado que existen m posibilidades para el valor de un estado. Análogamente se puede definir H_n a partir de una secuencia de longitud representada por valores de los m estados

de la variable. Sea $p(A_1 \dots A_n)$ la probabilidad de encontrar una secuencia con los estados $A_1 \dots A_n$, entonces la entropía por secuencia de longitud n se define como;

$$H_n = - \sum_{\{A_1 \dots A_n\}}^{m^n} p(A_1 \dots A_n) \log_{\lambda} p(A_1 \dots A_n) \quad (4.9)$$

4.1.2 Entropía local, condicional y dinámica.

También es posible considerar un sistema descrito en términos de dos variables aleatorias X e Y , definidas en un mismo espacio de probabilidades. Si X e Y son independientes, dado que la entropía es una propiedad aditiva, se cumple

$$H(X, Y) = H(X) + H(Y) \quad (4.10)$$

Sin embargo, la existencia de una dependencia estadística entre las variables implica una menor incerteza en la determinación de una a partir de la otra. Por esto, se introduce la cantidad denominada entropía local $H(X|y_i)$ que representa la incerteza acerca del valor de X cuando una determinada secuencia y_i de Y es observada;

$$H(X|y_i) = - \sum_{x_j}^n p(x_j|y_i) \log p(x_j|y_i) \quad (4.11)$$

Tomando el promedio de $H(X|y_i)$ sobre todos los y_i cuya probabilidad de ocurrencia es $q(y_i)$, se define la entropía condicional $H(X|Y)$ de X dada por Y como la incerteza remanente acerca de X dada por el conocimiento de la evolución de Y :

$$H(Y|X) = - \sum_{i=1}^{m1} \sum_{j=1}^{m2} q(y_i) p(x_i|y_j) \log p(x_i|y_j) \quad (4.12)$$

A partir de las ecuaciones (4.11) y (4.12) se puede definir la entropía local luego de un bloque específico como

$$H(A_{n+1}|A_{n_j} \dots A_{1_j}) = - \sum_{i=1}^m p(A_{(n+1)i}|A_{n_j} \dots A_{1_j}) \log p(A_{(n+1)i}|A_{n_j} \dots A_{1_j}) \quad (4.13)$$

y la entropía condicional luego de n bloques es

$$H(A_{n+1}|A_n \dots A_1) = \sum_{i=1}^m \sum_{j=1}^m p(A_{(n+1)i}|A_{n_j} \dots A_{1_j}) \log p(A_{(n+1)i}|A_{n_j} \dots A_{1_j}) \quad (4.14)$$

Además

$$H(A_{n+1} \dots A_1) = H(A_n \dots A_1) + H(A_{n+1}|A_n \dots A_1) \quad (4.15)$$

dado que la probabilidad de ocurrencia de cualquier bloque es igual a 1. Esto se puede escribir en general como;

$$H_{n+1} = H_n + H_{n+1|n} \quad (4.16)$$

Según la ecuación (4.16) es posible definir la incerteza relacionada con la determinación del estado A_{n+1} luego de n estados conocidos. Esta cantidad se la denomina entropía dinámica y según la ecuación (4.17)

$$h_n = H_{n+1} - H_n \quad (4.17)$$

Esta definición se completa definiendo $h_0=H_1$ que es la incerteza de determinar un estado sin información previa. Así mismo, el máximo nivel de incerteza [en unidades de $\log(m)$] es $h_n=1$. por lo tanto es posible definir la predictabilidad media como la diferencia entre las incertezas máxima y observada:

$$r_n = 1 - h_n \quad (4.18)$$

Esto significa que la predictabilidad se relaciona con la certeza que se tiene sobre el siguiente estado en el futuro en comparación con el conocimiento disponible.

A fin de analizar estas propiedades en la figura 4.2 se muestra la entropía condicional en función de la longitud de las secuencias en cuatro series de referencia. Aquí las diferencias entre la entropía condicional es mayor entre las secuencias de longitud tres y cuatro respecto de las demás. Esto significa que el crecimiento de la información es mayor entre el primer y el segundo día respecto de los días siguientes. En este rango, para la previsión de los parámetros climatológicos es posible afirmar que el examen de una duración más larga

conduce a una mejora de la predictabilidad del día siguiente. Por otro lado, si analizamos el comportamiento espacial de este parámetro podemos ver un comportamiento latitudinal donde se observa una mayor incertidumbre en Río Gallegos (lat = S52 °) y menor incertidumbre en las regiones tropicales (Tucumán y Campinas).

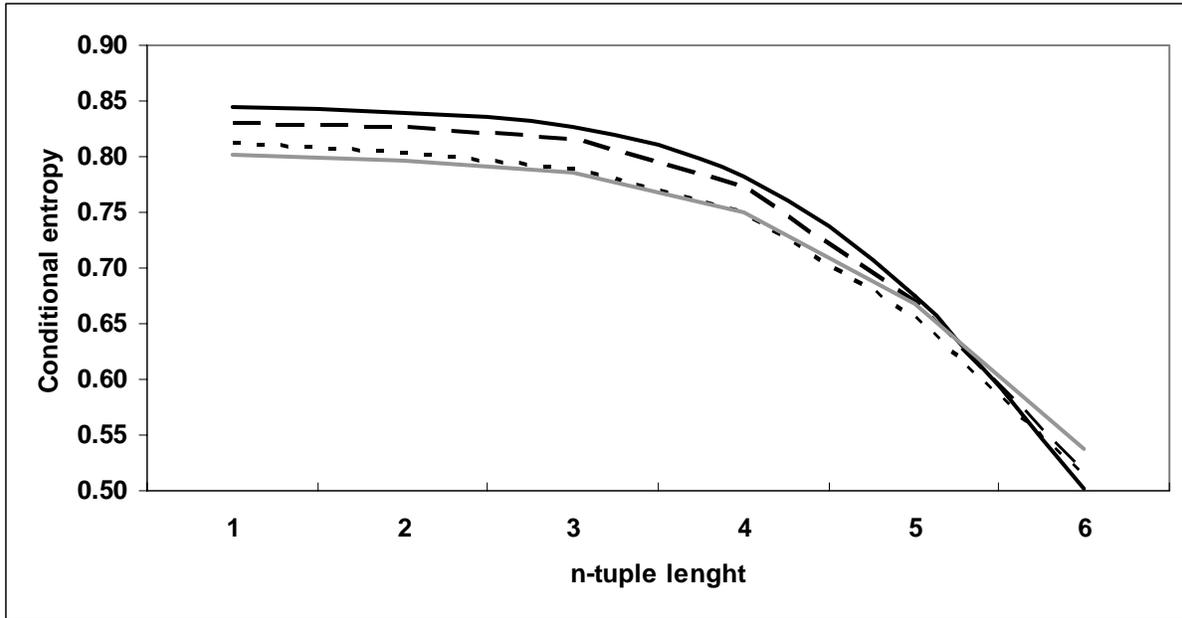


Figura 4.2. Entropía condicional (incerteza) en función de la longitud de secuencias de días (n-tupla) en Campinas (gris), Tucumán (puntos), Buenos Aires (líneas) y Río Gallegos (negro).

4.1.3 Entropía Conjunta e información Mutua

Cuando se consideran dos variables discretas x e y para el mismo tiempo t , es posible medir el grado de incertidumbre o la información asociada entre ellas. La cantidad que mide estas propiedades es la entropía conjunta $[H(x,y)]$. Si x e y pueden tomar m_1 y m_2 valores respectivamente, entonces la entropía conjunta se puede calcular como;

$$H(x, y) = \sum_{x=i}^{m_1} \sum_{y=j}^{m_2} p_{ij}(x, y) \log(p_{ij}(x, y)) \quad (4.19)$$

Donde p_{ij} representa la probabilidad de que la variable x se encuentre en el estado i simultáneamente que la variable y alcance el estado j .

La entropía conjunta varía desde la entropía mínima teórica ($H=0$) hasta $\log(m_1)+\log(m_2)$. La relación entre la entropía conjunta y las entropías individuales es;

$$H(x, y) \leq H(x) + H(y) \quad (4.20)$$

Esta relación muestra que la entropía conjunta es siempre menor a la suma de las entropías de cada variable. La igualdad solo es válida para el caso en que las variables x e y son independientes.

Por otro lado, es posible definir a la información mutua (MI) como una medida de la información compartida por dos variables. Esta cantidad puede definirse en función de las entropías individuales y conjunta de dos variables x e y según;

$$I(x, y) = H(x) + H(y) - H(x, y) \quad (4.21)$$

Si las dos variables son independientes, entonces la entropía conjunta es igual a la suma de las entropías individuales y por consiguiente la información mutua es cero.

En resumen, se puede expresar la relación entre las diferentes entropías de dos variables x e y a través del diagrama de la figura 4.3. En este diagrama de Venn se tiene que cada variable tiene su propia entropía $H(x)$ y $H(y)$. La región compartida (intersección entre las dos variables) se encuentra representada por la información mutua, mientras que la entropía condicional describe la información particular de cada variable. Finalmente la entropía conjunta es la suma de la información de las dos variables. A partir de este diagrama es claro que cuando las dos variables son independientes, la información mutua es 0, la entropía condicional es igual a cada entropía individual y la entropía conjunta es la suma de estas entropías individuales.

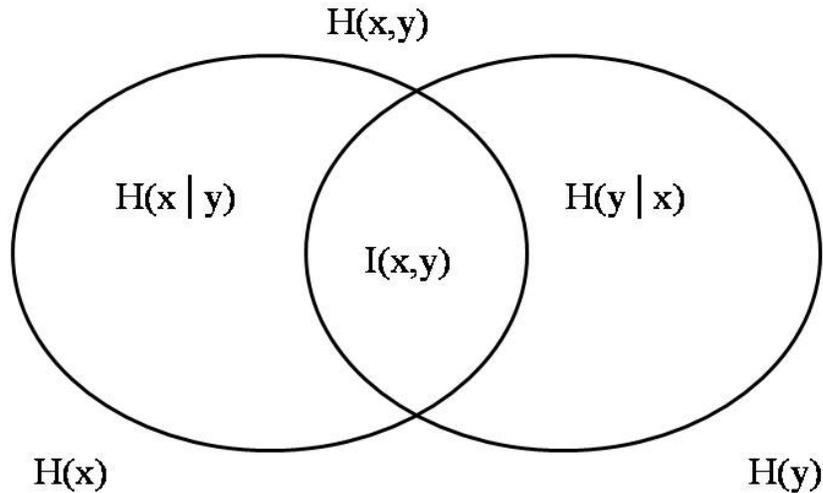


Figura 4.3. Diagrama de Venn que describe las relaciones entre las diferentes entropías entre dos variables x e y .

4.2 Análisis de Cluster.

En este tipo de análisis, se dispone de los valores de p variables X explicativas, para N objetos, y el objetivo es agruparlos en K grupos ($K < N$), de tal manera que los individuos que pertenecen a un grupo se parezcan lo más posible entre sí con respecto a esas variables, y a su vez difieran lo máximo posible de los individuos de otros grupos. Este planteamiento es completamente diferente de la metodología estadística habitual ya que aquí no hay una hipótesis previa.

Existen diferentes procedimientos para construir los grupos, y diferentes formas de determinar cómo se mide la similitud. Para ello se introduce el concepto de distancia entre las observaciones, que a su vez también viene determinado por el tipo de variables que se analizan, ya sean éstas cuantitativas como por ejemplo la temperatura, cualitativas ordinales en las que al resultado se le puede asignar un número cuyo orden tiene sentido, pero no la

diferencia entre dos valores, y cualitativas nominales que corresponden a una etiqueta y donde la similitud se determina como simple coincidencia de valores.

Para esta clasificación se utilizó el método P.A.M. (Kaufman y Rouseeuw, 1990) descrito en el capítulo 1. Básicamente este algoritmo se basa en la búsqueda de k objetos representativos del conjunto de datos (centroides), que representa la estructura de las observaciones. Un centroide se define como el grupo de objetos cuya desemejanza media respecto al resto de los objetos del grupo es mínima. Si j representa el centroide del grupo C , la distancia media (D) para todos los objetos de C respecto de j es calculada como;

$$D_j = \frac{\sum_{i \in C} d_{ij}}{N_j} \quad (4.22)$$

donde N es el número de miembros del grupo C . Luego de encontrar el conjunto de k centros, se construyen k grupos (clusters) asignando cada observación al centro más cercano.

4.2.1 Descripción de la clasificación sobre las series de Temperatura

En esta sección se describe la clasificación conjunta de las temperaturas máximas y mínimas diarias sobre la localidad de Corrientes. Este detalle pretende mostrar en detalle el alcance de la clasificación bivariada, describir las propiedades de los grupos, su asociación con la precipitación y diferentes patrones de circulación.

Así, al efectuar la clasificación mediante el método PAM, se obtienen cuatro grupos, los cuales están caracterizados por sus cuatro centroides. A partir de esto se obtiene una nueva serie de valores discretos donde cada día ya no está representado por las anomalías de temperatura, sino por un símbolo, el cual hace referencia a la pertenencia de grupo.

En la tabla 4.1 se muestran los valores de los centros acompañados de la cantidad de casos que fueron clasificados como pertenecientes a cada grupo. Analizando el valor de SC , se halla que para esta estructura el valor es de 0.57, lo que está evidenciando una clasificación matemáticamente consistente (ver datos y métodos).

Luego, analizando la conformación de los grupos, se observan algunas diferencias significativas en su estructura. El grupo 1, está caracterizado por valores superiores a los

medios, tanto en la temperatura máxima como en la mínima. Por lo tanto, estos días están asociados a condiciones cálidas. Lo mismo ocurre con el grupo 4, aunque en sentido inverso, donde las anomalías características de este conjunto son negativas, lo que evidencia días con condiciones frías. El grupo 2 representa los días con gran amplitud térmica, ya que se tienen valores positivos de T_x' , mientras que los valores de la temperatura mínima se encuentran cerca de los valores medios. Finalmente el grupo 3, con valores de T_x por debajo de la media y T_n cercanos a los valores medios, caracteriza a los días con escasa amplitud térmica.

	T_x'	T_n'	N
Grupo 1	5.4	4.8	7691
Grupo 2	1.1	0.2	13647
Grupo 3	-4.5	-0.5	6920
Grupo 4	-4.8	-5.8	5981

Tabla 4.1 Centroides correspondientes a los cuatro grupos obtenidos en Corrientes

Los grupos 1 y 4 están asociados a eventos que responden a una estructura definida, representando tanto a días cálidos como fríos respectivamente. Con esto surge una nueva pregunta, ¿es posible clasificar a los grupos 2 y 3 como representantes de estructuras de mayor escala?

Para responder esta pregunta se analiza el comportamiento en escala anual de las anomalías medias anuales de temperatura (T_x^* y T_n^*) en relación a la precipitación anual en Corrientes (figura 4.4). Aquí se observa que los años con mayor precipitación se ubican en el cuadrante correspondiente a anomalías medias de T_x negativas y T_n positivas, destacándose la ausencia de eventos secos (es decir precipitaciones anuales menores a 1200 mm, el valor medio corresponde a 1290 mm). También se observan algunos máximos locales en los años cálidos ($T_x^* > 0$ y $T_n^* > 0$), aunque en este cuadrante, sí existen valores deficitarios en la precipitación anual.

En cuanto a los años secos, estos se encuentran mejor definidos, encuadrados casi exclusivamente en años con condiciones de $T_x^* > 0$ y $T_n^* < 0$, donde la precipitación anual no superó los 1300 mm.

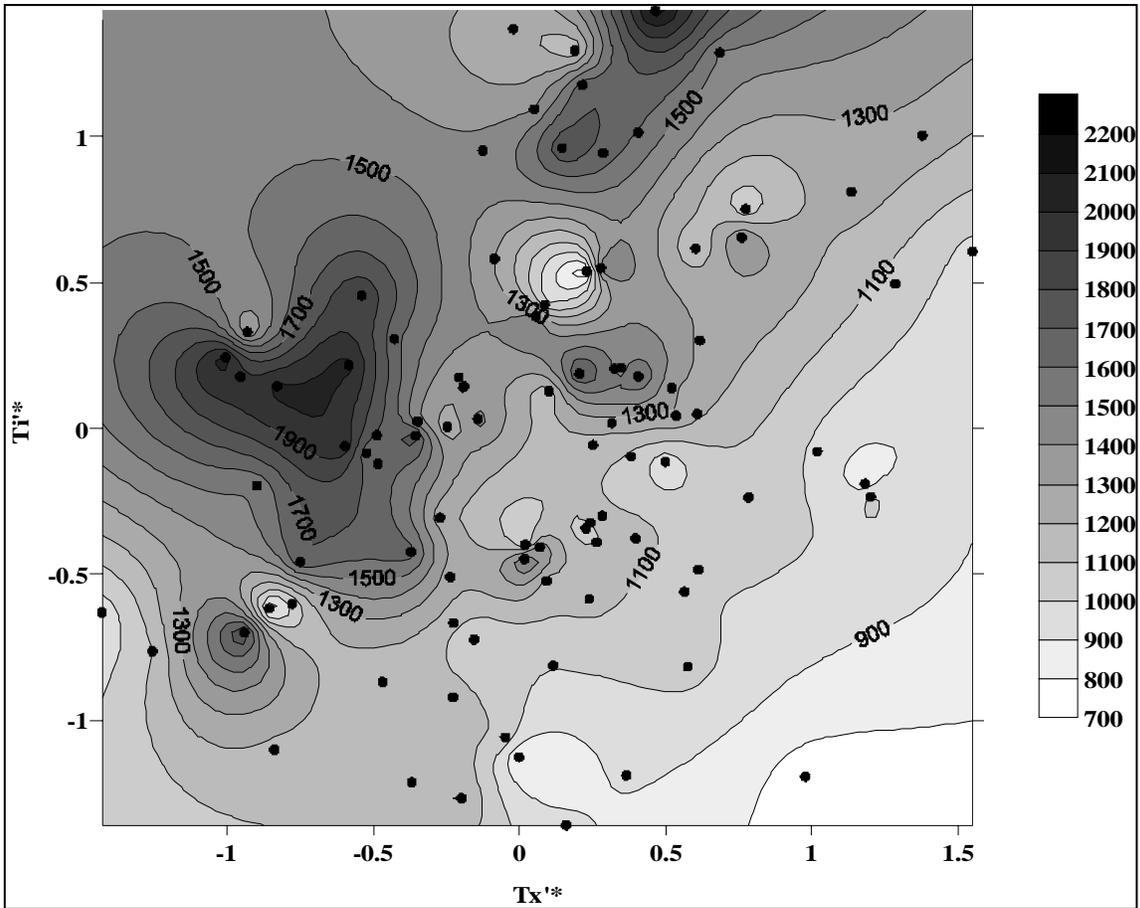


Figura 4.4. Relación entre las anomalías medias anuales de temperatura (T_x^* y T_n^*) y la precipitación anual en Corrientes.

En referencia a estos resultados a escala anual, se puede concluir que es condición suficiente la presencia de valores de $T_x^* > 0$ y $T_n^* < 0$ y $T_x^* < 0$ y $T_n^* > 0$ para la ocurrencia de años húmedos y secos respectivamente. Además la ocurrencia de estos fenómenos es más frecuente en estos cuadrantes que en cualquier otro.

Si bien a escala anual la asociación entre las anomalías de temperaturas extremas y la precipitación está bien definida, es necesario conocer lo que ocurre a escala diaria. Con este fin se analizó la asociación de la precipitación diaria con la ocurrencia de cada uno de los grupos.

En la tabla 4.2 se muestra la relación entre la precipitación diaria y la pertenencia a cada grupo. Debido a que todos los grupos tienen distinto tamaño, las frecuencias relativas se calcularon respecto al total de casos de cada cluster. En cuanto a la relación con los días

secos, se tiene que éstos ocurren preferentemente en presencias de las condiciones dadas por los grupos 2 ($T_x' > 0$ y $T_n' \approx 0$) y 4 ($T_x' < 0$ y $T_n' < 0$). Cabe mencionar que la ocurrencia de días secos dentro de la muestra asociada al grupo 3 ($T_x' < 0$ y $T_n' \approx 0$) es en general un 20% menor que bajo los restantes grupos.

Precipitación [mm]	frecuencia (%)			
	Grupo 1	Grupo 2	Grupo 3	Grupo 4
0	76%	78%	60%	89%
(0,5]	10%	10%	19%	7%
(5,10]	3%	3%	5%	2%
(10,15]	2%	2%	3%	1%
(15,20]	2%	1%	3%	0%
(20,25]	1%	1%	2%	0%
(25,30]	1%	1%	2%	0%
(30,35]	1%	1%	1%	0%
(35,40]	1%	1%	1%	0%
(40,45]	1%	1%	1%	0%
(45,50]	0%	1%	1%	0%
(50,55]	0%	0%	0%	0%
(55,60]	0%	0%	1%	0%
> 60	1%	1%	2%	0%

Tabla 4.2. Frecuencias porcentuales de precipitación acumulada en 24 hs relacionada con la clasificación de anomalías de Tx y Tn en Corrientes.

Si ahora se consideran los días con precipitación, se aprecia que el grupo 3 está asociado a la mayor cantidad de días húmedos. Así mismo este grupo está asociado preferentemente a los eventos de lluvias extremas (en este caso precipitación ≥ 50 mm), con el 3% de estos casos. Además, aunque en menor medida se encuentran días húmedos en los grupos 1, 2 y 4, este último está asociado a eventos de precipitación de escasa intensidad.

Con estos elementos, es posible establecer que la clasificación además de ser consistente matemáticamente, determina estructuras físicas con entidad propia. Es decir, se obtienen objetivamente cuatro grupos, los cuales se asocian a condiciones cálidas (grupo 1), secas (grupo 2), húmedas (grupo 3) y frías (grupo 4). En la figura 4.5 se muestra el espacio bidimensional conformado por las anomalías de temperatura máxima y mínima y la ubicación de los cuatros centroides que representa cada conjunto.

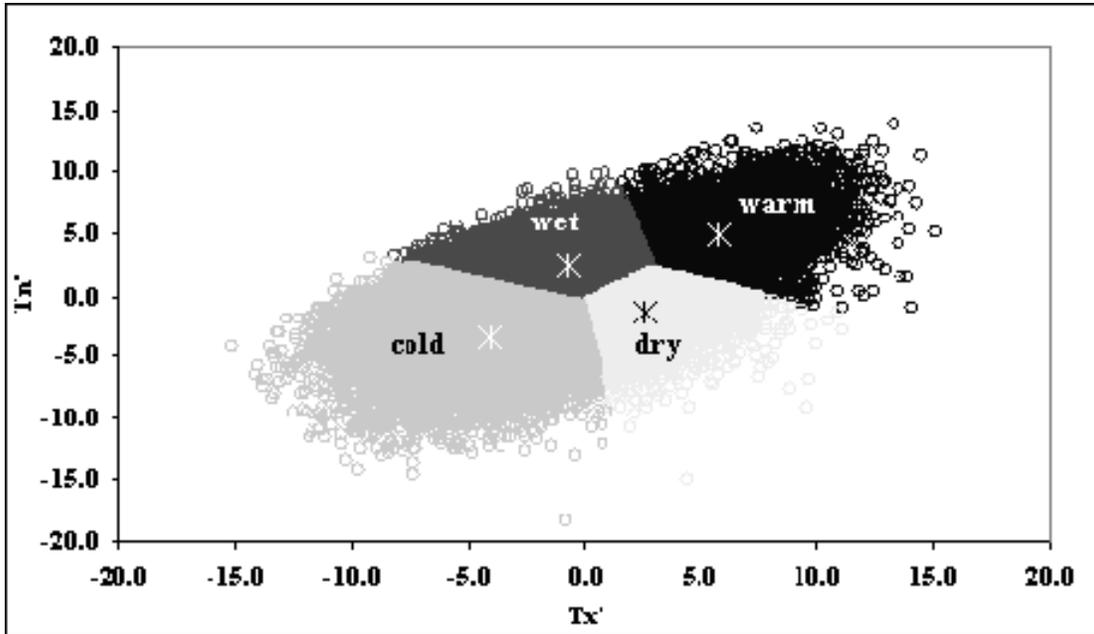


Figura 4.5. Grupos de datos en el espacio bidimensional Tx' - Tn' (círculos) y los centroides (cruces) correspondientes a los cuatro grupos obtenidos.

4.2.2 Asociación de la clasificación con tipos de circulación

Como ya se ha mostrado en las secciones anteriores, la clasificación aplicada a las anomalías de temperatura contiene información de procesos físicos de mayor escala. En particular, los grupos encontrados están asociados a diversos tipos de circulación con características propias. Para validar esta relación, se analizaron los campos medios asociados a los tipos de circulación diferenciados para cada grupo en Corrientes. Resultados similares al que se detalla para esta localidad se encontraron para otras estaciones de la región (Naumann, 2006). En las figuras 4.6 y 4.7 se muestran los campos medios de anomalías de altura geopotencial, temperatura, humedad específica y viento en el nivel de 1000 hPa. La información analizada corresponde al reanálisis NCAR/NCEP (Kalnay et al. 1996) y se obtuvieron a partir del website del Climatic Diagnostic Center.

Analizando la figura 4.6, los campos medios asociados con el centroide cálido muestra la evidencia del anticiclón semipermanente del Atlántico sur sobre la región mesopotámica. La advección térmica positiva prevalece en toda la región es la principal causa anomalías de temperatura extremas observadas en prácticamente todo el dominio, con los mayores

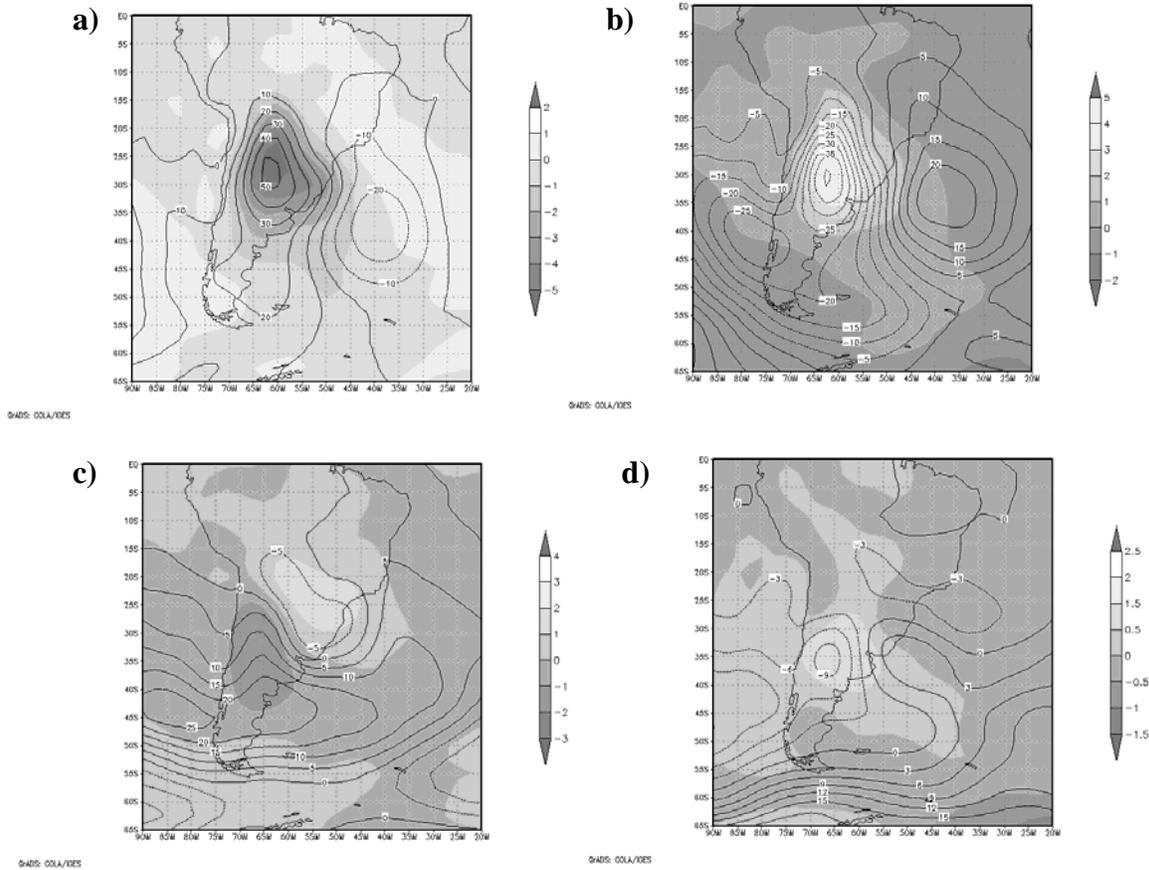


Figura 4.6. Campos medios de anomalías de altura geopotencial y temperatura en el nivel de 1000 hPa para los grupos a) frío, b) cálido, c) seco y d) húmedo en Corrientes.

valores en la región central de Argentina. El efecto opuesto se observa para los días clasificados como fríos, donde un sistema de alta presión dinámico asociado con irrupciones de aire frío domina la región.

Para las condiciones clasificadas como secas, se destaca la presencia de anomalías de altura geopotencial sobre Uruguay, excluyendo la influencia del anticiclón semipermanente del Atlántico. Mientras que para los días clasificados como húmedos se observa un eje de mínima presión asociado a la presencia de sistemas frontales en el norte de la mesopotamia. Este efecto se encuentra asociado a la presencia de cobertura nubosa y posible presencia de precipitación en dicha región. .

En la figura 4.7 se muestran los campos medios de de humedad específica y anomalías del vector viento asociados a cada grupo. Las áreas resaltadas indican la presencia de elevado

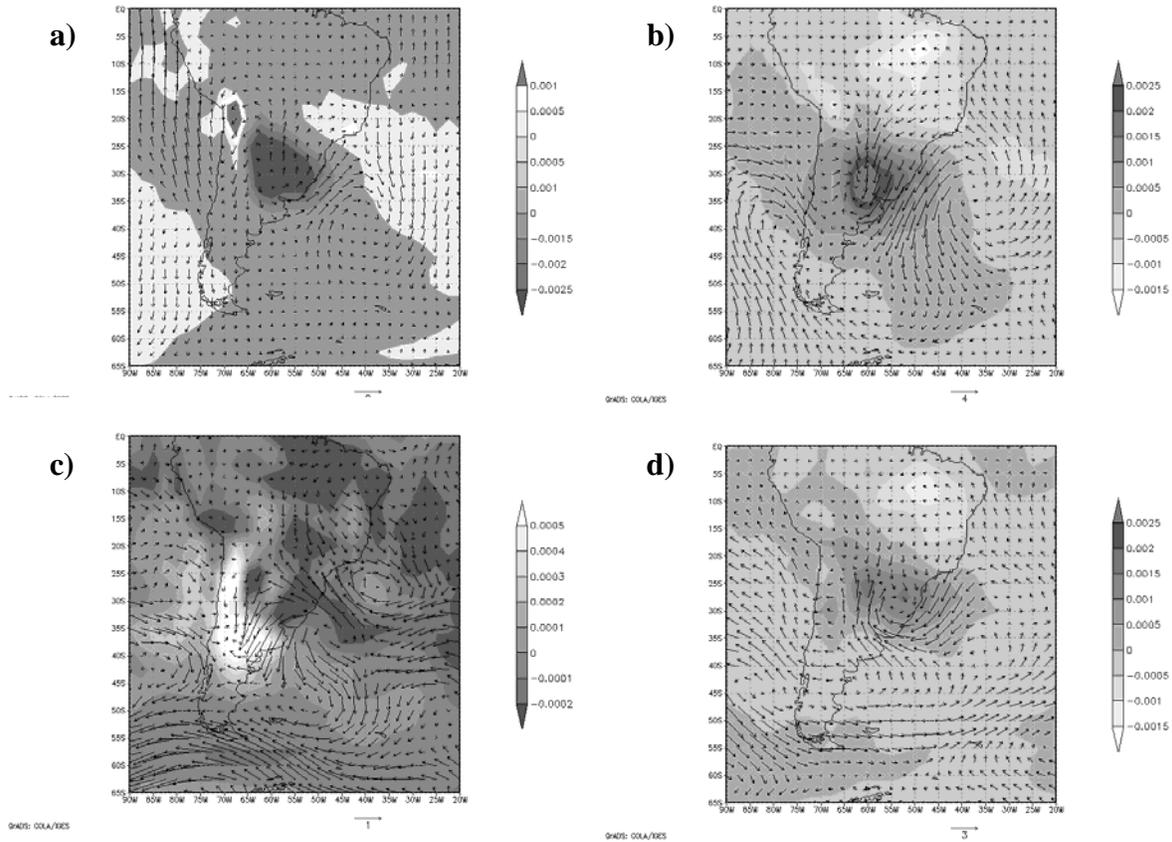


Figura 4.7. Campos medios de anomalías de humedad específica (sombreado) y anomalías del vector viento (vector) en el nivel de 1000 hPa para los grupos a) frío, b) cálido, c) seco y d) húmedo en Corrientes.

contenido de humedad para los grupos cálido y húmedo, pero con diferentes características. El campo asociado a los días cálidos se encuentran asociados a una intensa advección de temperatura y humedad desde el Amazonas, mientras que los días húmedos están preferentemente asociados con la presencia de sistemas convectivos y frontales en la región.

Utilizando estos resultados, se infiere sobre la relación de diversos tipos de circulación y la clasificación bivariada de anomalías de temperatura. En efecto, a partir de esto se puede concluir que si bien, existe una mayor cantidad de tipos de circulación que los cuatro grupos obtenidos, éstos pueden ser considerados como trazas de diversos patrones de

circulación definidos por estos grupos. Es decir, dentro de cada grupo podría existir una familia de patrones subsidiarios que forman parte de un grupo mayor.

4.3 Variaciones seculares de la clasificación

Como se indicó en la sección anterior, cada cluster determinado por una clasificación objetiva esta representado por cada centroide. Estos centroides se encuentran asociados a diferentes patrones de circulación, clasificados por las características medias de las anomalías de temperatura extremas. A través de la serie anual de ocurrencia de cada grupo, es posible analizar las variaciones de largo plazo de estas características. Para esto, se calcularon las tendencias lineales utilizando el método de cuadrados mínimos, donde el coeficiente de correlación representa la pendiente de cada curva (Tabla 4.3). Los coeficientes son considerados significativamente distintos de cero con un nivel de significancia del 5 %.

	<i>Warm</i>	<i>Wet</i>	<i>Dry</i>	<i>Cold</i>
Campinas				
Corrientes	-	+		
Tucumán	-	+		+
Pergamino	+	+	-	-
Pilar		+		-
Buenos Aires		+		
Santa Rosa	+	+	-	-
Río Gallegos	+			

Tabla 4.3. Tendencias de la ocurrencia anual para cada grupo en las estaciones de referencia. Los símbolos (+) y (-) representan los cambios positivos y negativos significativas al 5% respectivamente

La principal característica que surge de este diagnóstico es un incremento significativo de los días clasificados como húmedos, es decir con baja amplitud térmica, para todas las estaciones entre S25° y S45°. En Campinas se observa un incremento en la ocurrencia de este grupo, sin embargo con un nivel de significancia menor (10%). Solo en río Gallegos no

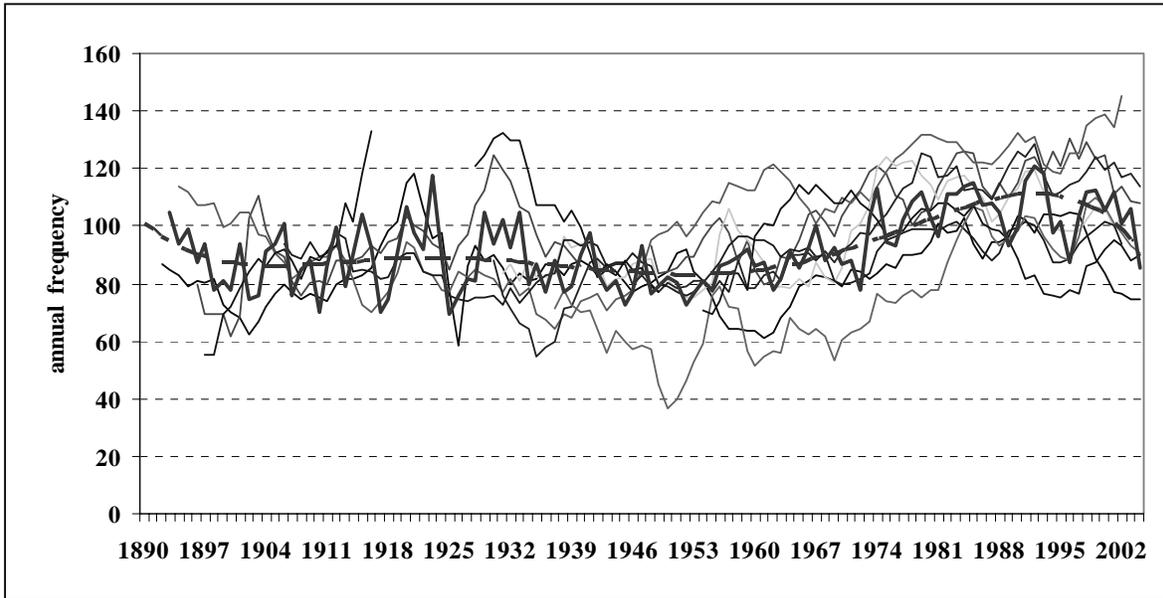


Figura 4.8. Frecuencia anual de ocurrencia del grupo húmedo en las estaciones de referencia (líneas delgadas), ajuste de polinomio de tercer orden (línea punteada) y el promedio regional (línea gruesa).

se registran variaciones respecto a la ocurrencia del grupo húmedo. El grupo asociado a días secos solo presenta disminuciones en su frecuencia anual en Santa Rosa, Pergamino y Buenos Aires, todas localidades ubicados en el centro de Argentina.

Por otro lado, los días cálidos ocurren menos frecuentemente en estaciones ubicadas en el norte de Argentina (Corrientes y Tucumán). En estos casos las tendencias negativas relacionadas a la temperatura máxima son principalmente debidos a una mayor ocurrencia de días húmedos acompañado de una menor ocurrencia de días clasificados como cálidos (Vargas et al, 2006 y Vargas y Naumann, 2008). El efecto contrario se observa en Pergamino, Santa Rosa y Río Gallegos donde se registra un aumento significativo de los días cálidos. Por otro lado, también se observa un comportamiento coherente respecto a los días fríos en la región central de Argentina. Aquí, se registran decrecimientos significativos en la ocurrencia anual de días dentro de éste grupo.

A partir de esta información es posible inferir que las variaciones en la ocurrencia del grupo húmedo es el principal efecto que domina las variaciones de la temperatura media en la

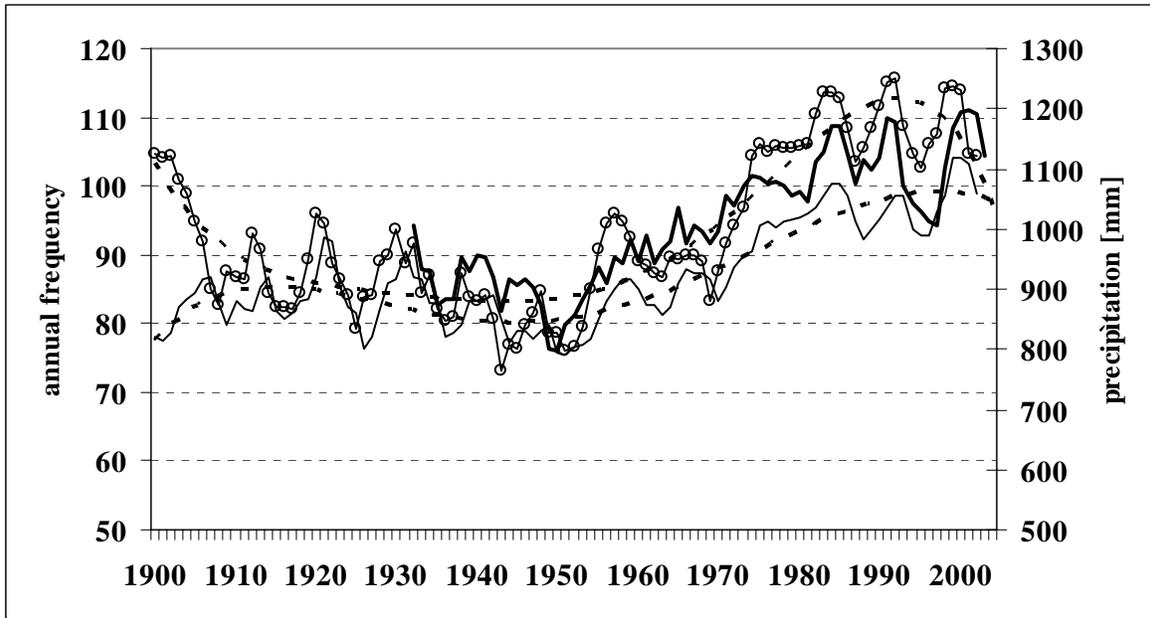


Figura 4.9. Frecuencia anual media regional de días con precipitación (línea sólida), días pertenecientes al grupo húmedo (círculos) y precipitación (línea gruesa) sobre seis estaciones de Argentina central y el ajuste polinomial de quinto orden (línea punteada)

región. Además se observa un comportamiento homogéneo en la región central de Argentina, donde en general la frecuencia de días cálidos se incrementa, mientras que la cantidad de días secos y fríos se observa en descenso.

En la figura 4.8 se muestra la coherencia temporal de la ocurrencia anual de días clasificados como húmedos. Un comportamiento similar se observa en estas series, donde las mayores diferencias entre estaciones no excede el 20%. Respecto a las variaciones climáticas, se observa la presencia de un mínimo en la ocurrencia de días húmedos en finales de la década de 1940 y dos máximos en la década de 1920 y 1990. Esta variable comienza a decrecer en los comienzos del siglo veintiuno.

Así mismo, la frecuencia de días húmedos y días con precipitación es coherente en la región central de Argentina. La Figura 4.9 muestra el promedio regional de la frecuencia anual de días con precipitación, días clasificados como húmedos y la precipitación anual en seis estaciones de Argentina norte y central (Tucumán, Corrientes, Buenos Aires, Pergamino, Pilar y Santa Rosa). Aquí se observa que las series generadas utilizando la

clasificación conjunta de las temperaturas máximas y mínimas permiten reproducir las series de precipitación diaria (principalmente valores regionales de frecuencia anual y totales anuales de precipitación). Además, el mínimo y máximo observados en la década de 1940 y 1990 respectivamente, se observan en la frecuencia anual de días de lluvia y precipitación anual. Estos resultados coinciden con el aumento de las precipitaciones observadas por diferentes autores, como Minetti y Vargas (1998), Minetti et al (2004), Liebmann et al (2004), Haylock et al (2006), Barros et al (2008), y entre ellos los informes del IPCC.

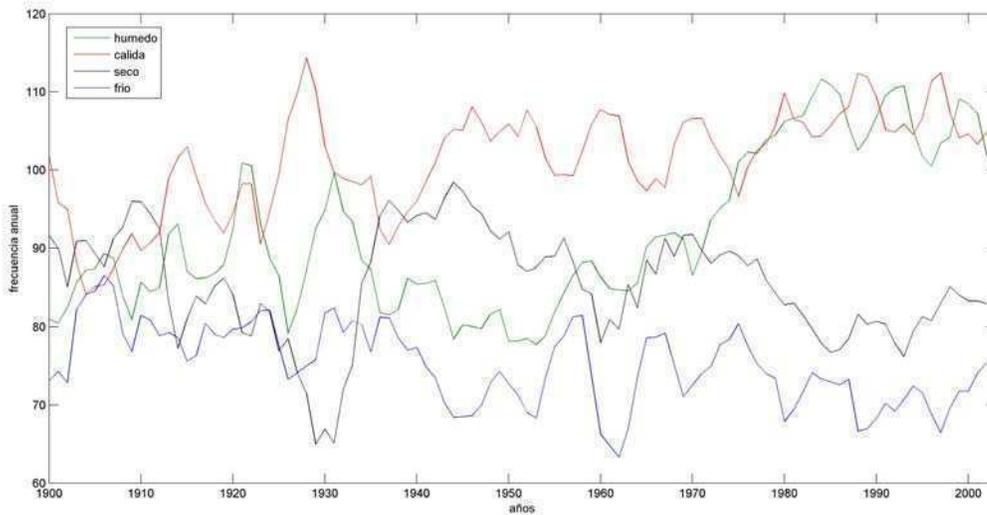


Figura 4.10. Frecuencia anual media regional de ocurrencia de días húmedos (verde), secos (negro), cálido (rojo) y fríos (azul).

Si se analiza la frecuencia anual de los cuatro grupos simultáneamente (figura 4.10) se observa un comportamiento opuesto entre la ocurrencia anual de días húmedos y secos, donde el grupo de días secos presenta valores mínimos durante las décadas de 1920 y 1990 y un máximo en la década de 1950. Así mismo, alrededor de la década de 1940, se registra un cambio en la ocurrencia de días cálidos y fríos. A partir de este punto de inflexión, se observa un incremento regional en la cantidad de días cálidos acompañados por un decrecimiento en el número de días fríos.

4.4 Estimación de las distribuciones asociadas con las probabilidades de transición.

Para caracterizar los procesos climáticos, es importante tener un detallado conocimiento del comportamiento temporal de los parámetros que lo definen. Uno de estos parámetros es la memoria de los procesos físicos que actúan sobre el sistema (Ebeling, 2002). Estas propiedades específicas pueden ser analizadas a través de cambios en la persistencia y memoria del sistema representada por la entropía condicional.

De acuerdo al algoritmo relativo al análisis de cluster cada día se encuentra totalmente descrito por uno y solo un símbolo. A partir de esto es posible definir $P_i(X_1; \dots; X_i)$ como la probabilidad de ocurrencia de una secuencia de longitud i del grupo o símbolo X . Esta probabilidad describe la persistencia de cada cluster sobre i pasos de tiempo. La secuencia de probabilidades $P_i(X)$ representa los casos en que el estado X se mantiene por i días antes de que se produzca un cambio de estado y comience otra secuencia. Esta cantidad se denomina “distribución de cambio de estado” (Nicolis et al, 1997).

La figura 4.11 muestra las distribuciones de cambio de estado correspondientes a cada grupo en Buenos Aires. Aquí se observa que para los días cálidos y fríos las distribuciones son similares a procesos Markovianos, pero para los días húmedos y secos la persistencia es mayor que la asociada a un proceso de Markov.

Además es posible ligar un posible cambio climático en el caso de que las distribuciones de cambio de estado cambien en el largo plazo. Por esto encontrar una distribución teórica que caracterice esta información permite extender la investigación de estos procesos y vincular de manera robusta con cambios en el sistema climático. Para esto, Gabriels y Neumann, 1962 y Nicolis et al, 1997 han evaluado los diferentes ajustes teóricos para describir las distribuciones de cambio de estado. En la región analizada en este trabajo, los mejores ajustes corresponden a distribuciones exponenciales (Naumann y Vargas, 2009), como;

$$p_{(i)} = p_1 e^{(b(1-i^2))} \quad (4.23)$$

$$p_{(i)} = (1 - p_1) p_1^{(i)} \quad (4.24)$$

donde p_1 representa la probabilidad de transición de cada grupo y $p_{(i)}$ es la probabilidad ocurrencia de una de i días en el mismo estado.

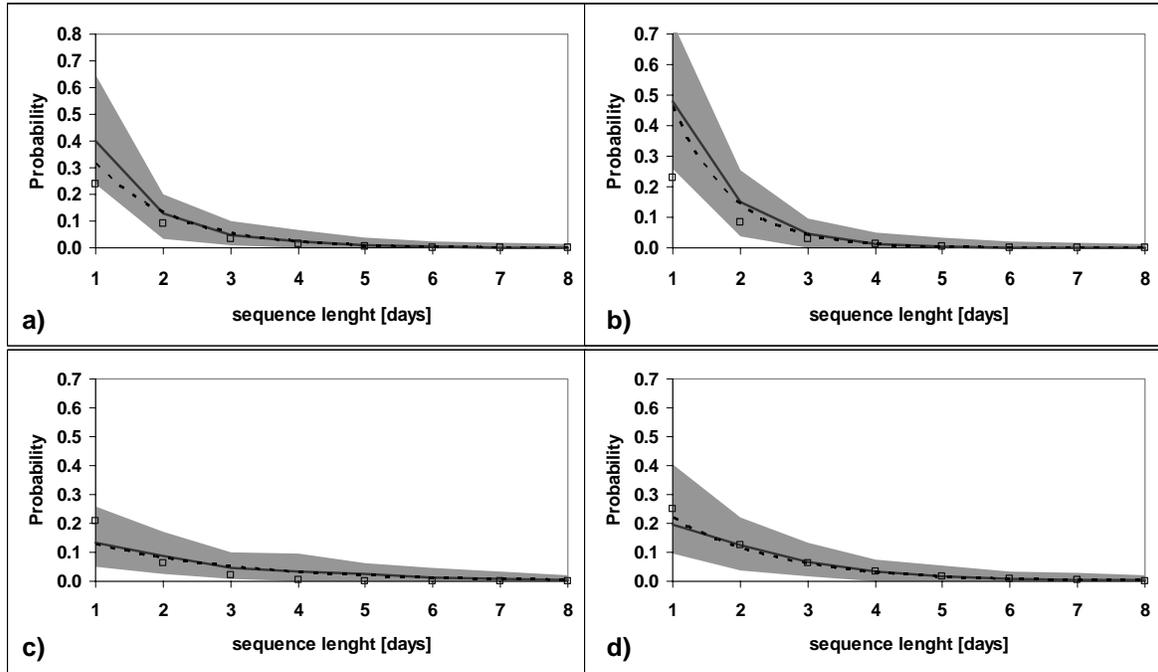


Figura 4.11. Distribución de cambio de estado calculada (línea sólida), ajuste exponencial (línea punteada) y valores del proceso markoviano (ec. 4.24 en cuadrados) para los grupos a) húmedo, b) seco, c) cálido y d) frío en Buenos Aires.

4.5. Variaciones espaciales de las incertezas

Si se analiza el comportamiento espacial de la entropía se estudian las estaciones de la región que aseguran una cantidad de información de temperatura máxima y mínima en a lo sumo 20000 días, para asegurar una estimación estable y robusta de los clusters.

La figura 4.12 muestra el campo de entropía H para secuencias de dos días de longitud calculado de acuerdo a la ecuación (4.15). Esta figura refuerza la idea de un gradiente meridional, inicialmente sugerido por los resultados de la figura 4.2. Además surgen algunas inferencias sobre la circulación regional y su predictabilidad.

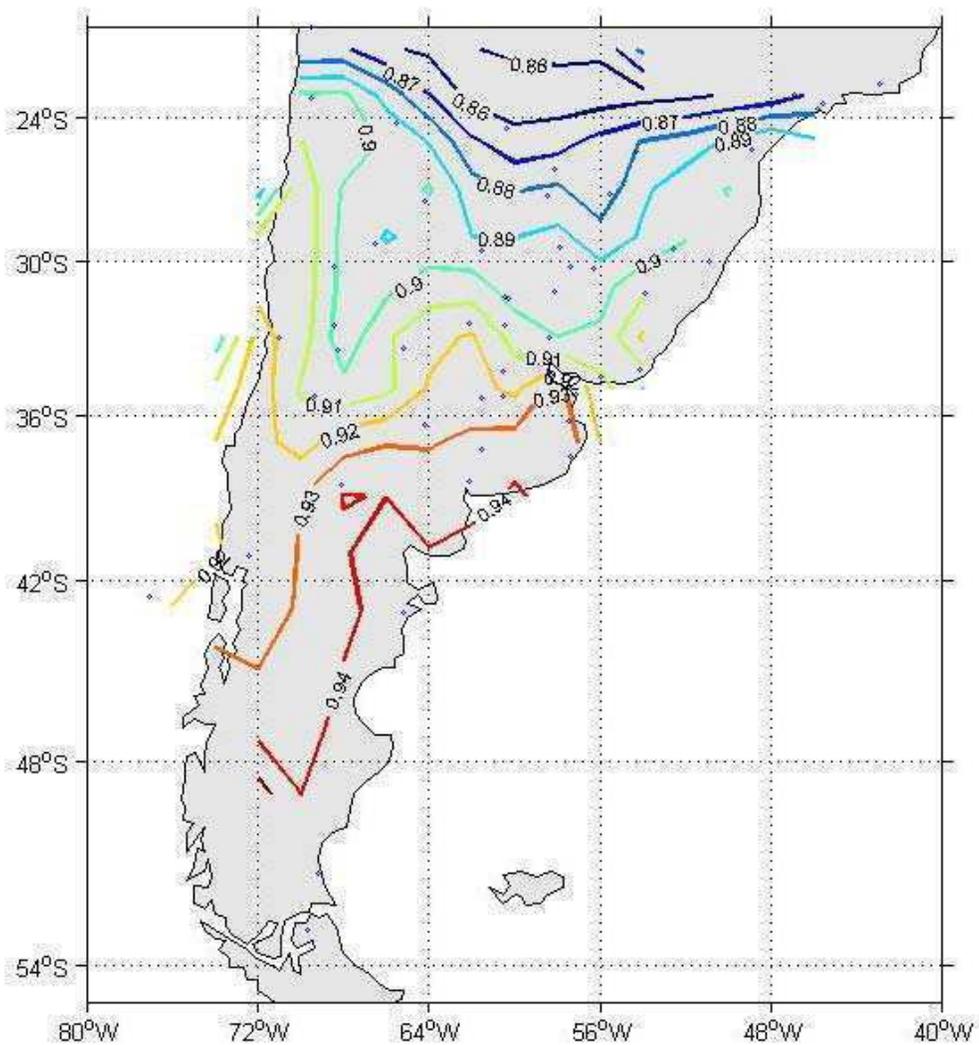


Figura 4.12. Distribución espacial de entropía de bloque H para las secuencias de dos días en 54 estaciones de la región.

En la región de la Patagonia (sur de $S40^\circ$) se observan los valores más elevados de entropía, lo que señala la dirección preferencial de los sistemas sinópticos (frentes fríos, ciclones y sistemas anticiclónicos, etc.). Otro aspecto que se debe mencionar es el papel de los Andes sobre las trayectorias de los sistemas sinópticos, evidenciado por la presencia de un gradiente zonal, principalmente en la Patagonia donde los vientos son dominantes del oeste. Este efecto de la cordillera es menos importante para latitudes al norte de $S30^\circ$.

En la región central de Argentina y las regiones costeras del Brasil existe una región de transición entre las latitudes medias y los regímenes tropicales. Esta última región se caracteriza por una mayor predictabilidad debido a la persistencia de las advecciones cálida de la Amazonia. Estos resultados sugieren que los riesgos asociados con el mismo

modelo de predicción son diferentes para cada región. En otras palabras, la entropía mide la cantidad de información que se necesita para obtener un modelo eficiente.

4.6 Variaciones temporales de la entropía y persistencia

Para muchas aplicaciones prácticas, no resulta de mucho interés conocer solamente la incerteza media de las predicciones. Sin embargo es de mayor utilidad la elaboración de una predicción basada en las observaciones a partir de una secuencia concreta o durante un espacio temporal dado. En la figura 4.13 se muestra la entropía condicional para los grupos de días clasificados como fríos y cálidos y las probabilidades de transición entre estados calido a calido, frío a frío y entre frío y caliente y caliente a frío. Las dos primeras transiciones representan la persistencia mientras que las dos últimas son representativas de la antipersistencia.

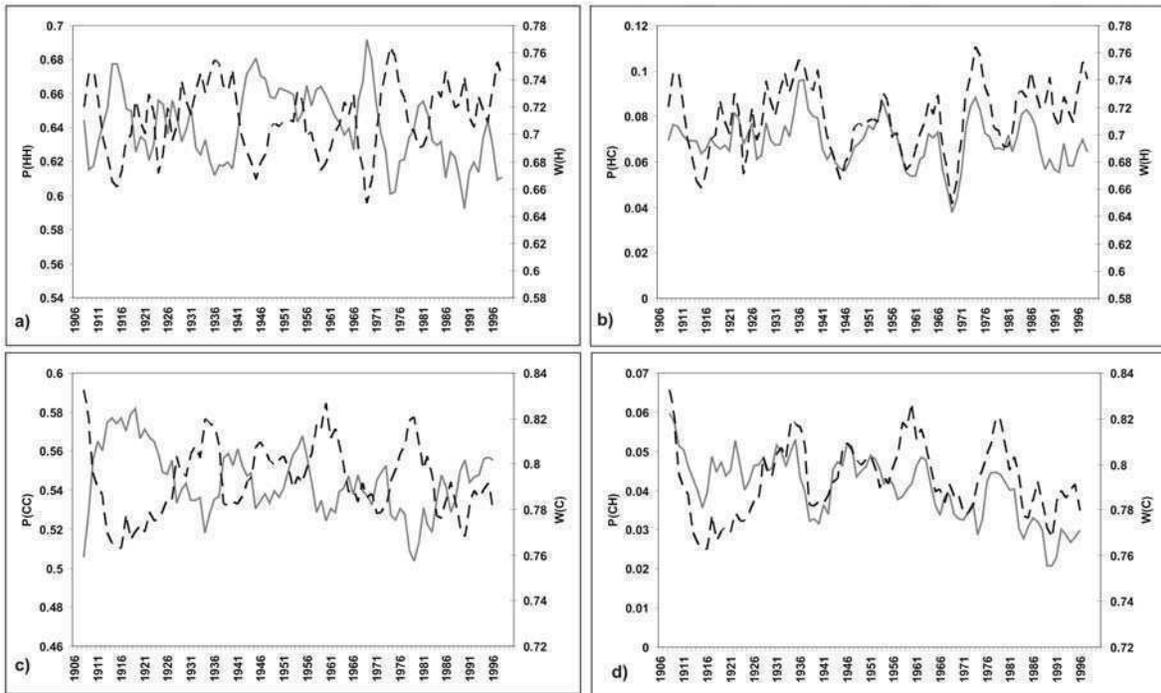


Figura 4.13. Entropía condicional (puntos) para días cálidos (H) en el panel superior y para días fríos (C) en el panel inferior y la probabilidad de transición entre H-H (a), H-C (b), C-C (c) y C-H (d) en Buenos Aires.

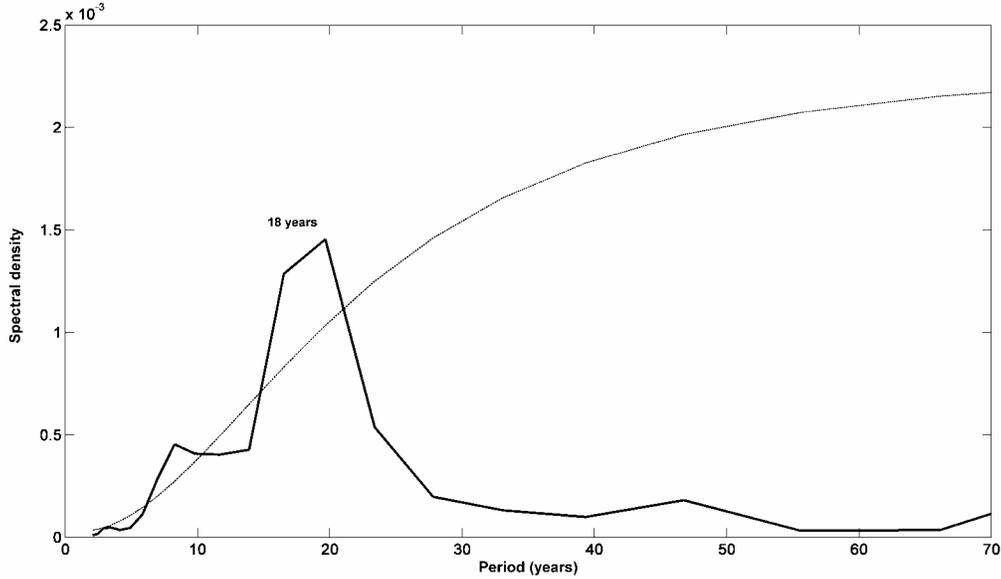


Figura 4.14. Densidad espectral de la entropía condicional para el grupo de los días cálidos en Buenos Aires.

Aquí se observa que la entropía condicional muestra variaciones significativas con el tiempo. En ambos casos, estas variaciones de $\pm 0,10$, representan cambios en la predictabilidad entre valores de 15 -25%. Esto significa que existen años especiales donde la predictabilidad aumenta / disminuye hasta dos veces más que los valores medios.

Un comportamiento temporal opuesto se observa entre la entropía condicional asociada al conjunto de días fríos y cálidos. Es decir esta variable disminuye en el caso de que aumente la persistencia y la entropía condicional aumenta a una mayor presencia de transiciones entre los estados cálido y frío y su inversa.

Respecto a estas variaciones, se encontraron algunas periodicidades recurrentes en la región. En la figura 4.14 se muestra la densidad espectral de la entropía condicional para el grupo de días cálidos en Buenos Aires. Este análisis muestra una periodicidad de alrededor de 18 años donde la seguridad de la predicción basada en la persistencia crece/decrece con el tiempo. Un incremento de la entropía condicional se observa en las décadas de 1930, 1950 y hacia finales de la década de 1970. Estos dos máximos son coincidentes con dos saltos climáticos observados en muchas variables en la región (Minetti and Vargas, 1998). Esto puede estar relacionado debido a que un incremento en el desorden del sistema puede

implicar un consiguiente cambio de estado. Luego de estos eventos, la entropía condicional comienza a decrecer hasta alcanzar un mínimo aproximadamente diez años después.

CAPITULO 5

VARIABILIDAD INTRAESTACIONAL DE LA TEMPERATURA

Los procesos o fenómenos que evolucionan con el tiempo en general pueden ser descriptos por ecuaciones diferenciales. En el caso del análisis del estado térmico del aire de una localidad, los fenómenos que la describen pueden ser representados por un solo número en cada tiempo. Como se describió en los capítulos anteriores, y para el caso más simple el valor de la temperatura para el día i puede ser representado como:

$$T_i = F(T_{i-1}) \quad (5.1)$$

donde F es la función que describe la relación con T_i con el valor del día anterior.

Si se considera la presencia de efectos no lineales, se tiene que estos modelos que son altamente simplificados, pueden tener un comportamiento dinámico complicado. Sin embargo, es posible aproximar este tipo de comportamiento desde el punto de vista de las irregularidades y oscilaciones caóticas producto de la evolución de fenómenos difíciles de describir en términos de modelos simples. Lorenz tomó este punto de vista para estudiar el comportamiento turbulento. El mostró que el complicado comportamiento de un fluido puede ser modelado por una secuencia de $x, F(x), F^2(x), \dots$, la cual retiene parte del comportamiento caótico del fluido original (Tien-Yien and Yorke, 1975).

Un aspecto de este resultado evidencia que si la solución a un sistema dinámico es no periódica, las pequeñas incertezas en las condiciones iniciales pueden crecer tanto hasta hacer el pronóstico no mejor que una realización aleatoria del sistema. Las predicciones numéricas del tiempo indican en la actualidad que la predictabilidad es relativamente buena hasta un período aproximado de tres semanas (Simmons and Hollingsworth 2002). Sin embargo, si bien la predictabilidad más allá de las tres semanas es baja, aun sigue siendo de gran interés. Especialmente, ciertas estructuras tanto espaciales como temporales pueden ser altamente predecibles para períodos mayores a las tres semanas. La detección de estas estructuras es difícil debido a que en general existen estructuras impredecibles superimpuestas que dominan los efectos (Del Sole and Tippet, 2007). Por ejemplo, la evolución de una variable en una ventana temporal en particular (puede ser un período menor a una estación del año) puede ser altamente predecible más allá de las tres semanas, pero ésta predictabilidad puede ser difícil de detectar en un análisis que considera a toda la serie (todas las estaciones en conjunto). Lo mismo ocurre con una región en particular, donde la predictabilidad local puede no ser detectada en un análisis de mayor escala. Además, las componentes que son predecibles en períodos mayores a las tres semanas,

pueden ser persistentes y por lo tanto explicar gran parte de la variabilidad de las medias mensuales, incluso si estos explican solo un poco de la variabilidad diaria (Shukla 1981a). Siguiendo esta línea de razonamiento, Lorenz (1969) y Shukla (1981b) describen que las estructuras de gran escala tienden a ser más persistentes y por lo tanto más predecibles respecto de procesos de menor escala. Ciertas características del sistema atmósfera-océano que favorecen oscilaciones de períodos mayores son aquellas que por su naturaleza están limitados a variar más lentamente.

En su trabajo de 1968, Lorenz definió a los sistemas casi transitivos como a los sistemas que para una solución particular exhiben diferentes propiedades entre diferentes segmentos de un período de tiempo suficientemente grande. Por esto, cuando una componente del sistema físico tiende a comportarse más lentamente, fluctuaciones de baja frecuencia se ven favorecidas y segmentos separados de una solución dependiente del tiempo pueden poseer estadísticas diferentes. Lorenz (1976) propone una serie de simples modelos numéricos que simulan el comportamiento de la atmósfera, los cuales evidencian que las soluciones son en general casi-intransitivas. Se tiene que los fenómenos casi intransitivos pueden ser representados por simples ecuaciones. Siguiendo el trabajo de Lorenz (1976), se describe un sistema simple, representado por una ecuación diferencial de orden cúbico,

$$X_{n+1} = a(3X_n - 4X_n^3) \quad (5.2)$$

Donde “a” es una constante positiva. Si bien, esta ecuación no es el resultado de simplificar las ecuaciones que gobiernan el sistema atmósfera-océano, esta tiene características en común con algunos modelos de la atmósfera que permiten ilustrar algunos aspectos matemáticos de la casi intransitividad.

Si $a > 1$, la solución de (5.2), generalmente divergen. Si $a \leq 1$ y $|X_n| \leq a$ se puede demostrar que $|X_{n+1}| \leq a$. Por esto, la elección de un valor inicial X_0 con $|X_0| \leq a$ determinará una secuencia X_0, X_1, X_2, \dots , con cada término variando entre $-a$ y a . Aunque la ecuación no se deriva de ninguna ecuación meteorológica, se puede pensar a X_n como el valor de algún parámetro de la atmósfera en el día n (por ejemplo, la temperatura del aire en superficie). Mediante el análisis de esta solución teórica es posible comprender algunos procesos comunes con las ecuaciones que gobiernan el sistema atmósfera-océano. Por ejemplo, si se

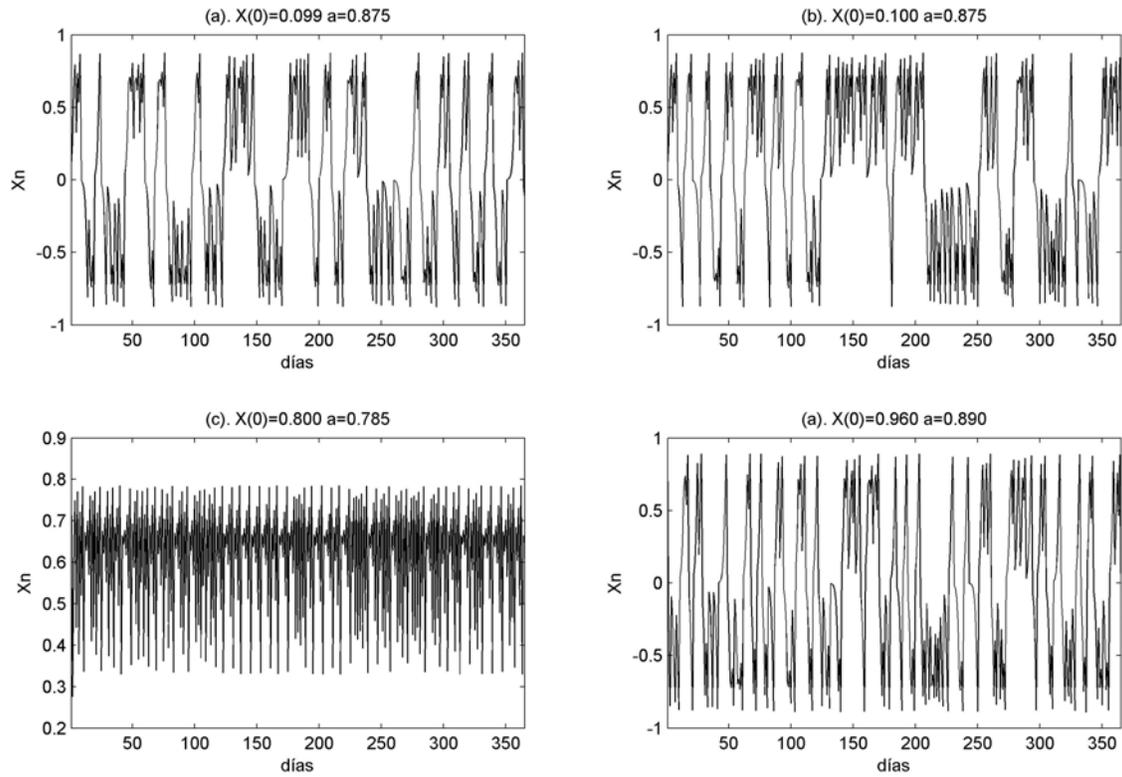


Figura 5.1. Soluciones de la ecuación (5.2) para 365 días con distintos valores de condición inicial y parámetro a .

consideran las condiciones de borde constantes, la ecuación (5.2) provee soluciones asociadas a procesos estacionarios ($a=7/8$ y $X_n=0$ o $X_n^2=13/28$). También esta solución es inestable respecto a pequeñas perturbaciones, e incluso muestra periodicidades exactas de dos días en forma análoga al comportamiento de la atmósfera. Una discusión en mayor detalle de este tipo de soluciones y sus implicancias se pueden encontrar en Lorenz (1963, 1968, 1976) y Palmer and Hagedorn (2006).

A modo de ilustrar el comportamiento de la ecuación (5.2) en la figura 5.1 se muestran cuatro soluciones de ésta ecuación para distintos valores de condiciones iniciales y del parámetro “ a ” para 365 días. Como primer impresión se puede observar que las soluciones muestran cuasi-periodicidades que varían desde 5 días hasta varios meses. Aparentemente la pérdida de predictabilidad a largo plazo en ausencia de perfectas observaciones (se

supusieron $X_0=0.099$ y $X_0=0.010$ en la figura 5.1 a y b) es significativa, incluso teniendo un perfecto conocimiento de las ecuaciones que gobiernan el sistema.

Estos resultados son un ejemplo de las numerosas propiedades físicas en que la predictabilidad varía significativamente con el tiempo. Por lo tanto deben existir condicionantes tanto internos como externos al sistema climático que pueden provocar en ciertas condiciones procesos físicos persistentes que se reflejan en las series como cuasi-ciclos. Esta predictabilidad que se observa más allá de tres semanas se puede identificar utilizando filtros apropiados en espacio y tiempo. Varias técnicas se han utilizado para identificar estructuras predecibles en conjuntos de datos climáticos. Barnet y Preisendorfer (1987) utilizaron el análisis de correlación canónica para identificar relaciones entre la temperatura superficial del mar y la temperatura del aire en superficie, Lorenz (1965) usó la descomposición en valores singulares para identificar las condiciones iniciales que maximizan el crecimiento del error. Deque (1988) y Renwick and Wallace (1995) usaron análisis de componentes principales para identificar los patrones más predecibles en modelos de pronóstico operacional. Venzke et al. (1999) utilizaron la relación entre el ruido y la señal en un análisis multivariado para identificar variables predecibles en escenario de cambio climático. Utilizando el análisis discriminante Schneider and Griffies (1999) encontraron componentes que maximizan el poder predictivo.

En este capítulo se propone explorar las estructuras que proveen una mayor predictabilidad en las series de temperatura máxima y mínima diaria sobre las estaciones de referencia en el Sudeste de Sudamérica utilizando el análisis espectral wavelet. Este método provee una forma de representar la variación de periodicidades con el tiempo, siendo una poderosa herramienta matemática que provee una representación en tiempo-frecuencia de una señal analizada en el dominio del tiempo (Percival y Walden, 2000). A partir de ésta metodología no sólo es posible determinar valores particulares de frecuencias en series no estacionarias, si no también se puede determinar el tiempo en que ocurren estos cambios. Dada la ventaja de esta metodología en el análisis de la variabilidad climática, se encuentra que se ha utilizado en diversos trabajos en diferentes escalas temporales. Se utilizó para investigar tendencias en series de temperatura en Inglaterra Central (Baliunas et al, 1997), para estudiar el ENSO (Torrence y Compo, 1998) y para analizar cambios en la temperatura global (Park y Mann, 2000).

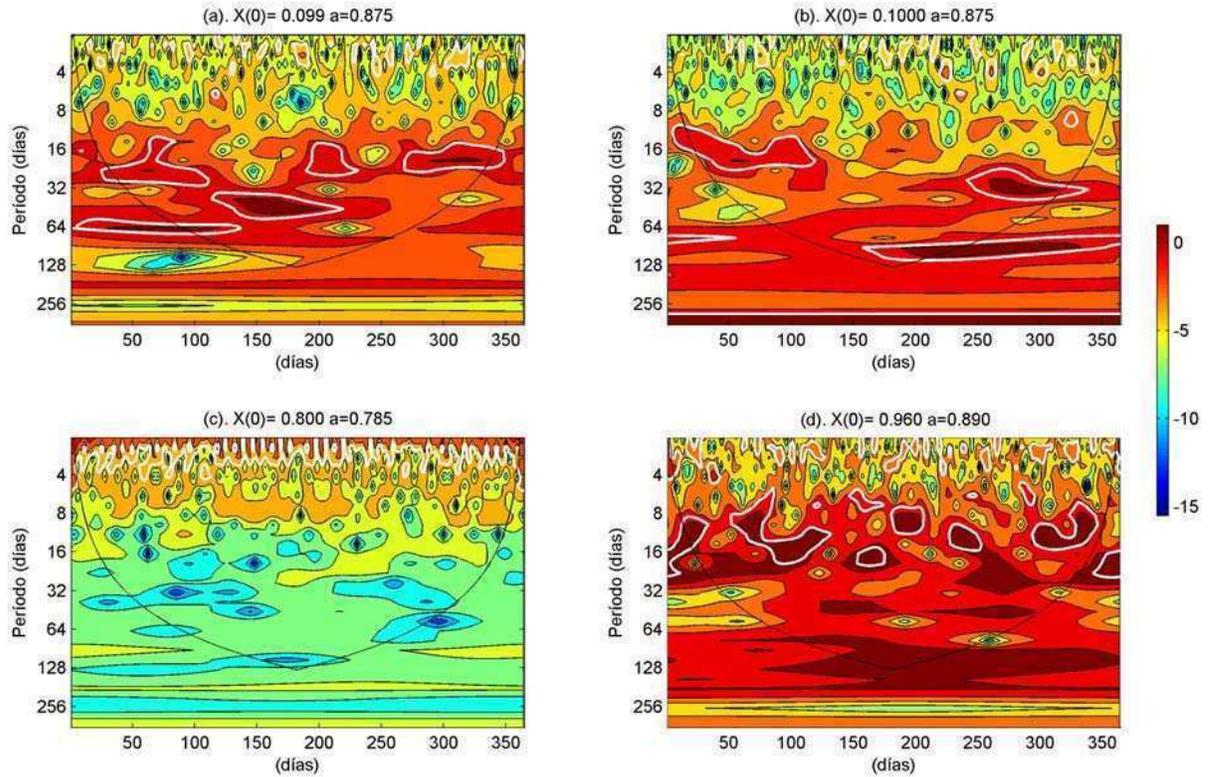


Figura 5.2. Espectro Wavelet estimado en base a las soluciones de la ecuación (5.2) mostradas en la figura 5.1. Los contornos blancos representan el nivel de significancia del 5%, respecto de un modelo autoregresivo.

En la figura 5.2 se muestra el espectro wavelet para las series simuladas según la ecuación (5.2). Aquí se observa que para pequeños cambios en las condiciones iniciales, las propiedades espectrales de las series varían significativamente. Si suponemos como condición inicial a $X_0=0.099$ (figura 5.2a) se tiene que existen perturbaciones con período de 60 días al inicio de la simulación, mientras que cerca del día 150, la señal más importante pasa a estar centrada en un período de 40 días. Además durante toda la simulación, existen superpuestas, ondas con períodos de entre 2 y 5 días. Pero si la condición inicial varía en una centésima ($X_0=0.100$) las propiedades espectrales de la solución varía significativamente. Al comienzo del registro se observa una periodicidad centrada en 16 días, mientras que a partir del día 160 comienza a dominar una onda de 70 días. Para otras condiciones iniciales y valores del parámetro a , se pueden obtener

soluciones solo con periodicidades entre 2 y 5 días (figura 5.2c) y oscilaciones entre 2 y 14 días (figura 5.2d).

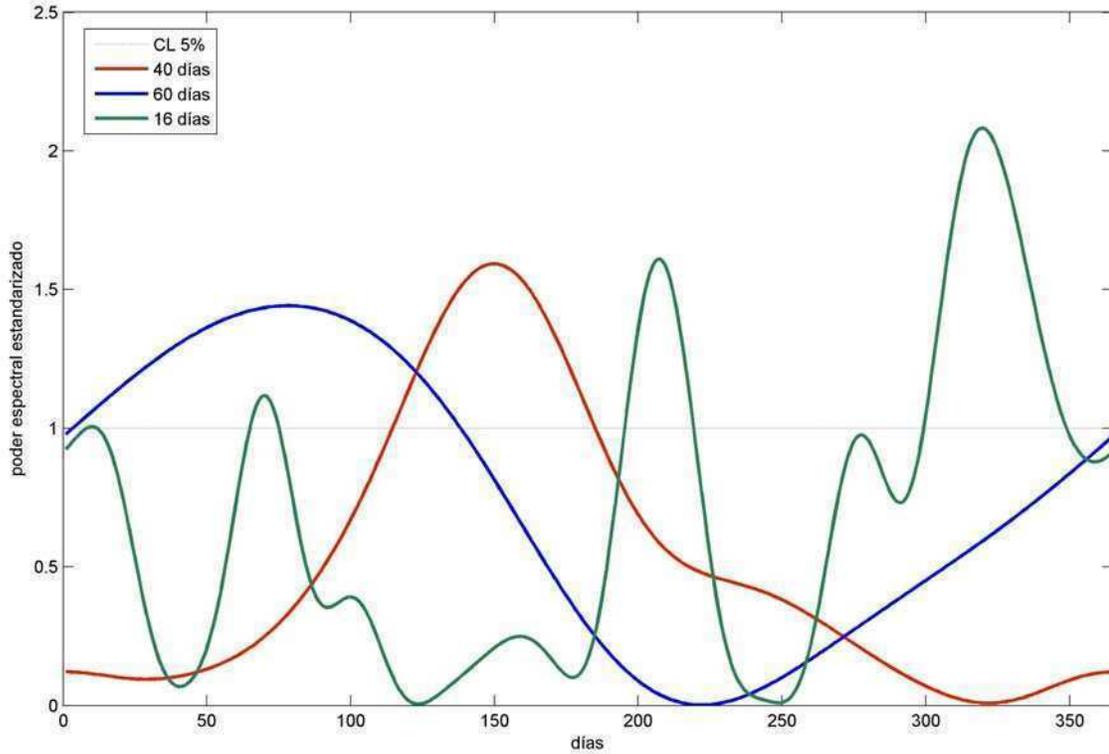


Figura 5.3. Poder espectral wavelet estandarizado para la solución de la figura 5.1a discriminado para cuasi-ciclos con períodos de 16, 40 y 60 días.

A partir de esta metodología es posible identificar los períodos en que aparecen fenómenos más persistentes que se evidencian sobre las series temporales como la presencia de cuasi-ciclos. Por esta razón si existiera una periodicidad recurrente, es posible diagnosticar para que intervalos de tiempo esta posee una mayor influencia a través del monitoreo de la densidad espectral asociada a cada período en particular. En la figura 5.3 se muestra la densidad espectral estandarizada (el cociente entre la densidad espectral empírica y el valor del intervalo de confianza asociado a una densidad espectral teórica) utilizada para detectar la presencia de oscilaciones cuasi-periódicas con períodos centrados en 16, 40 y 60 días. A través de esta descripción se observa que durante los primeros 140 días de la simulación dominan ciclos de 60 días, mientras que entre los días 100 y 200 la onda con mayor

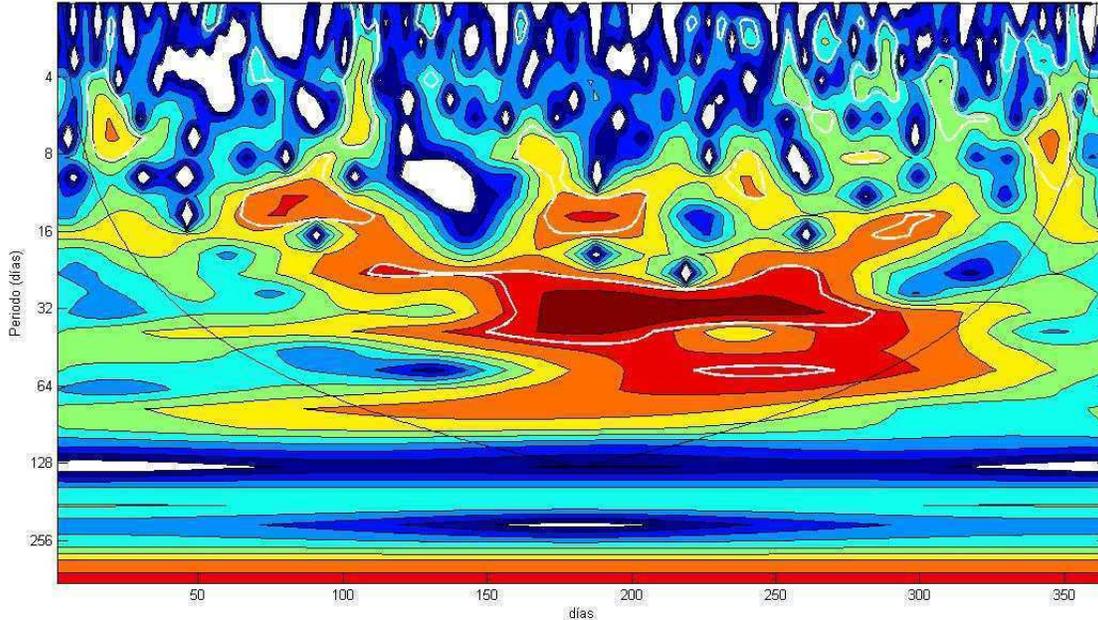


Figura 5.4. Espectro Wavelet estimado para la temperatura mínima en S. M. de Tucumán durante el año 1976. Los contornos blancos representan el nivel de significancia del 5%, respecto de un modelo autoregresivo.

preponderancia es aquella asociada a 40 días. Finalmente, desde mediados hasta el fin de la simulación aparecen intermitentemente oscilaciones cuyo período preferencial está centrado en 16 días. Debido a la característica transitoria de estas propiedades espectrales, éstas no son detectables si se consideran períodos de análisis considerablemente mayores a los de cada onda en particular. Por ejemplo, si en el análisis anterior se hubiera considerado los 365 datos, difícilmente podría ser observable algún pico espectral significativo.

Por esta razón, la identificación en el tiempo de las estructuras espectrales que son producto de la presencia de fenómenos físicos transitorios permite detectar períodos en que la predictabilidad del sistema aumenta y por consiguiente obtener una mejora en el momento de la elaboración de un pronóstico objetivo, información principalmente útil para pronósticos que van más allá del límite de predictabilidad propuesto por Lorenz.

5.1 Estimación espectral wavelet sobre las series de referencia

Con el objetivo de detectar las estructuras térmicas que producen fenómenos persistentes se efectúa el análisis espectral wavelet sobre las series de temperatura máxima y mínima diaria. A partir de este análisis se propone determinar las principales características espectrales de los anchos de banda preferenciales dentro de la escala intraestacional en que las cuasi-periodicidades producto de efectos no lineales tienden evidenciarse sobre las series de temperatura diaria en el sudeste de Sudamérica.

Inicialmente, para ilustrar los alcances del análisis se muestra en la figura 5.4 el espectro wavelet sobre la serie de temperatura mínima en San Miguel de Tucumán para el año 1976. En esta figura, además de las periodicidades asociadas a la variabilidad dentro de la escala sinóptica, se observan densidades espectrales significativas para cuasi-ciclos de períodos entre 25 y 50 días elongados principalmente en la dirección del tiempo. En este caso, se observa la preferencia a ocurrir irrupciones cálidas/frías intensas durante el invierno con un período como el descrito anteriormente. Este concepto está relacionado con la aparición de procesos físicos o patrones de circulación que tienden a modular el transporte meridional de calor con una frecuencia en particular dentro del espectro intraestacional (Lamb, 1972, Ghil and Mo 1991a y 1991b y Higgins and Mo, 1997).

Este efecto se evidencia en las series de temperatura de la región y dado que la transformada wavelet también es un filtro de banda, [con una función de respuesta conocida (la función wavelet)] es posible reconstruir la serie temporal original o simplemente las características de la serie para el ancho de banda deseado. En este caso la serie de tiempo reconstruida es la suma de la parte real de la transformada wavelet sobre las escalas deseadas;

$$x'_n = \frac{\delta_j \delta_t^{1/2}}{c_\delta \psi_0(0)} \sum_{j=j_1}^{j_2} \frac{\Re\{W_n(s_j)\}}{s_j^{1/2}} \quad (5.3)$$

Este filtro es una función de respuesta dada por la suma de las funciones wavelet entre las escalas j_1 y j_2 .

En la figura 5.5 se muestran las anomalías de temperatura mínima para el año 1976 y la reconstrucción de la serie según la ecuación (5.3) en el ancho de banda con períodos entre 30 y 60 días. Esta reconstrucción se puede interpretar como el aporte a la amplitud de las anomalías de cada día debido a la variabilidad con períodos entre 30 y 60 días. Aquí se

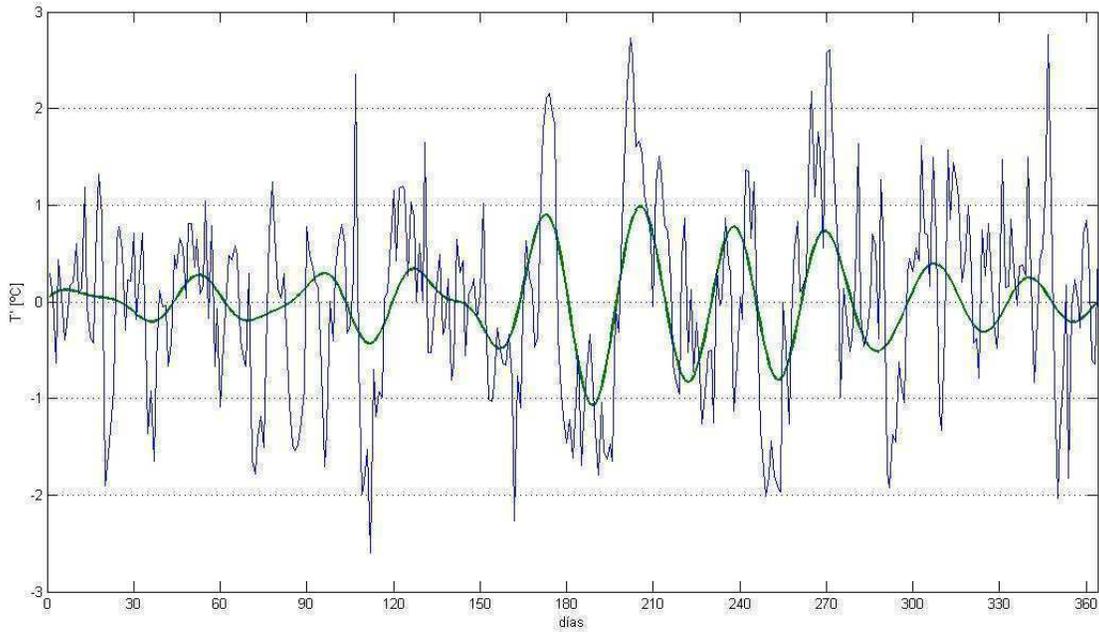


Figura 5.5. Anomalías de temperatura mínima (azul) y la reconstrucción de las anomalías en el ancho de banda entre 30 y 60 días (verde) en San M. de Tucumán durante el año 1976.

observa que durante el invierno, estación en la que se observa la mayor densidad espectral, la amplitud de la reconstrucción de las anomalías en el rango intraestacional comienza a crecer y a ponerse en fase con respecto a las anomalías totales. En este caso, aproximadamente entre los meses de mayo y setiembre la amplitud de la reconstrucción crece significativamente, evidenciándose con una amplitud de cercana a 1 °C. Esto indica que la variabilidad del tipo intraestacional representa en algunos casos más del 40% de la variabilidad total. En esta línea de razonamiento, Naumann et al (2007) muestran la existencia de fluctuaciones con períodos entre 20 y 90 días sobre las series de temperatura diaria, siendo las más frecuentes aquellas cuyo período se ubica entre 30 y 60 días. Resultados similares fueron encontrados en la región por Ghil and Mo 1991b, Minetti 1991 y Minetti y Vargas 2005.

En la figura 5.6 se muestran las distribuciones de las densidades espectrales discriminada por períodos. Si bien en todas las estaciones domina la variabilidad en el rango sinóptico

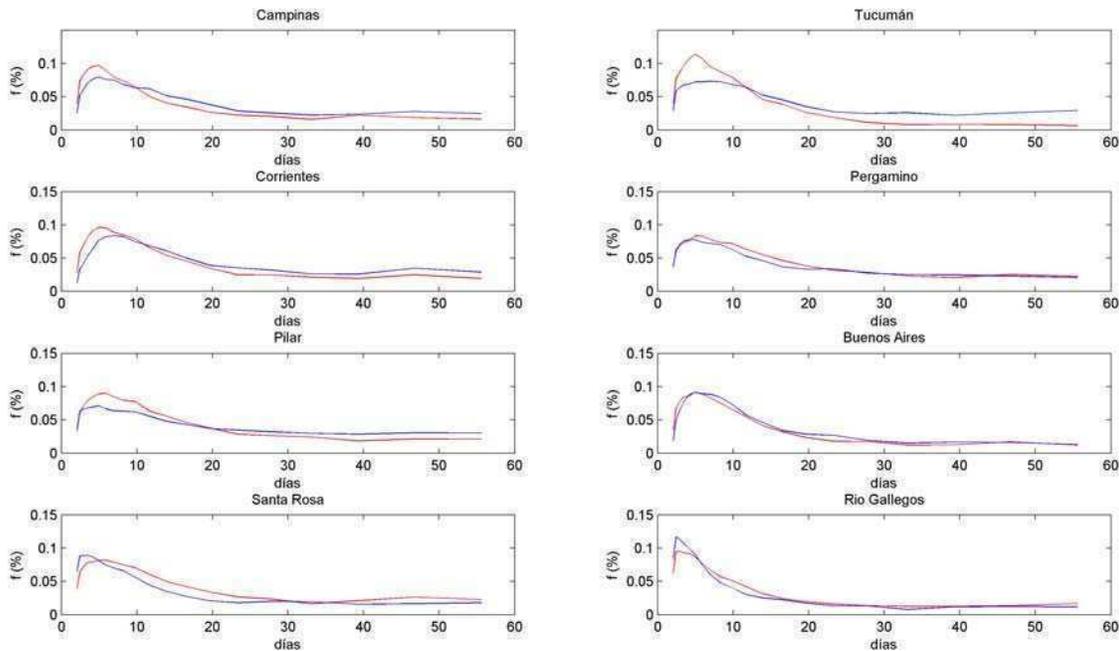


Figura 5.6. Distribución de las densidades espectrales significativas por períodos para la temperatura máxima (rojo) y mínima (azul) sobre las estaciones de referencia.

(entre 2 y 15 días), los períodos entre 20 y 60 días muestran una ocurrencia en ningún sentido despreciable. En general para todas las estaciones entre el 20 y 30% de los días analizados de cada registro se evidencia alguna señal intraestacional, lo que implica si consideramos que las estaciones de referencia tienen en general más de 40000 datos diarios, que entre 8000 y 10000 días del total están asociados a este tipo de variabilidad. Por esto, el diagnóstico de los procesos en que las variaciones intraestacionales tienden a tomar mayor amplitud, (por ejemplo, cuando la densidad espectral es significativa respecto a un marco teórico adecuado), pasa a tener relevancia al momento de introducir esta información en modelos de diagnóstico y pronóstico objetivo tanto estocásticos como dinámicos (Strauss and Shukla, 1981, Lau and Chang, 1992, Doblas-Reyes et al, 1998).

En la figuras 5.4 y 5.5 se muestra que la variabilidad en la banda de 30 y 60 días, el año 1976 evidencia una mayor energía espectral en esta banda durante los meses de invierno. A partir de esto surge la pregunta sobre si existe una estación preferencial donde tiende a evidenciarse este tipo de efectos no lineales. En la figura 5.7 se muestra la distribución de la

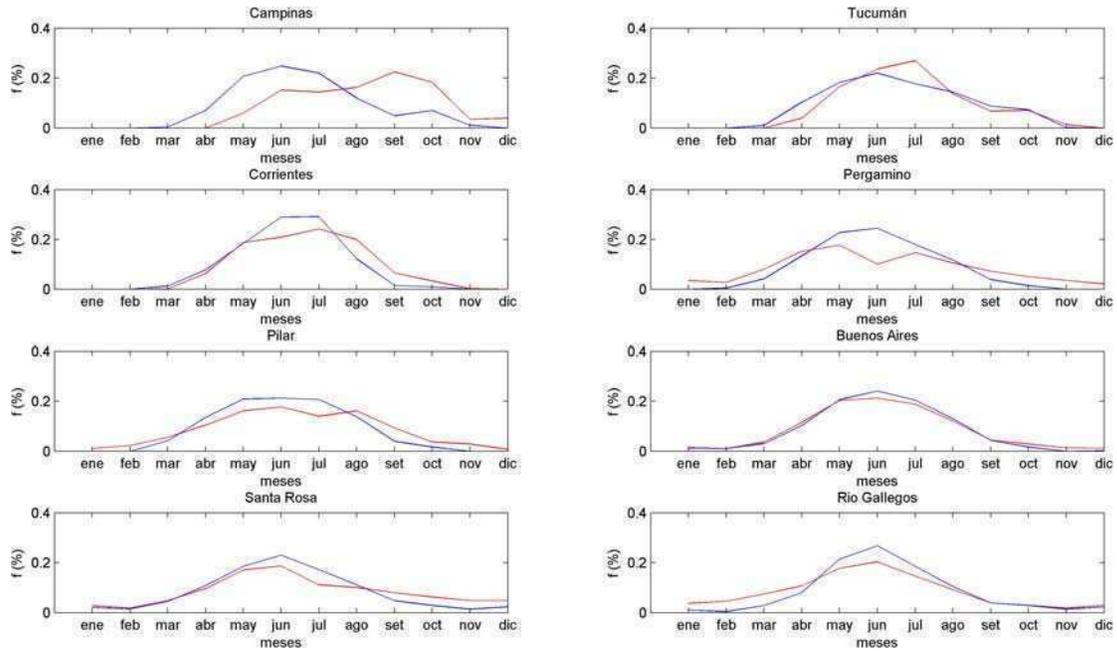


Figura 5.7. Distribución anual de la ocurrencia de densidades espectrales significativas en el ancho de banda de 30 y 60 días para la temperatura máxima (rojo) y mínima (azul) sobre las estaciones de referencia.

ocurrencia de densidades espectrales significativas en función de los meses del año. Para todas las estaciones de referencia y tanto para la temperatura máxima como mínima se observa que los meses invernales son los que evidencian la mayor ocurrencia de esta variabilidad. Para la temperatura máxima la ocurrencia de esta señal intraestacional parece ser un poco más compleja, donde en algunas estaciones (Campinas, Tucumán, Pergamino, Pilar y Santa Rosa) esta característica tiende a tener una distribución bimodal. Aquí, los máximos tienden a ocurrir al inicio y final del invierno, donde en particular en las localidades donde se observa este comportamiento, también los máximos se asocian al inicio y final de una marcada estación seca.

La mayor variabilidad de la temperatura máxima en la ubicación de la fecha con mayor influencia del efecto intraestacional también se observa si se efectúa un análisis regional. En la figura 5.8 se muestra la distribución espacial del día del año en con mayor cantidad de densidades espectrales significativas en el ancho de banda de 30 y 60 días. En efecto,

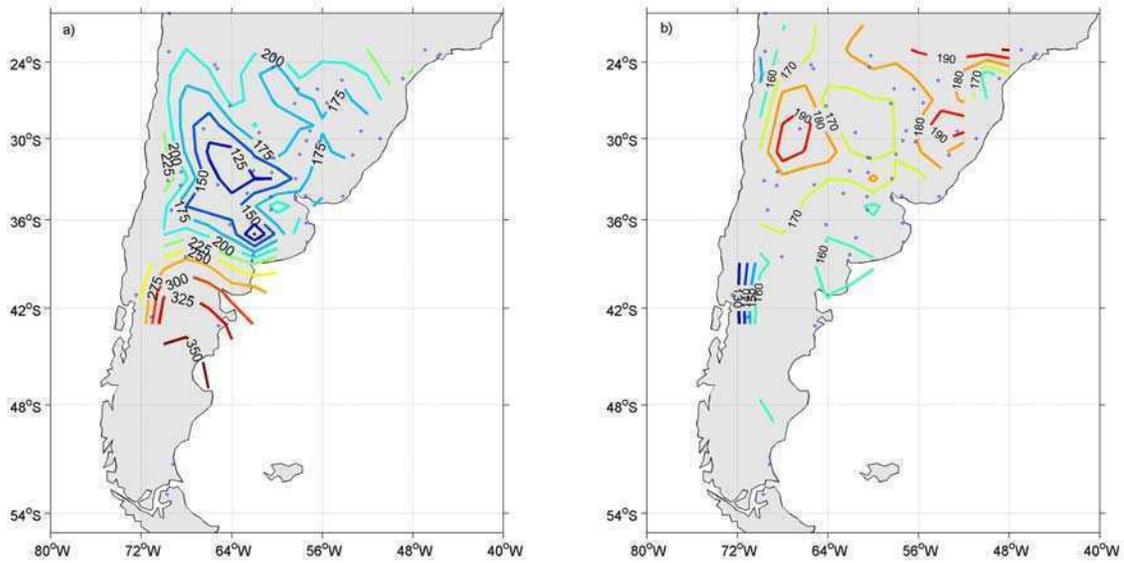


Figura 5.8. Distribución espacial del día del año en con mayor cantidad de densidades espectrales significativas en el ancho de banda de 30 y 60 días para la temperatura máxima con isolíneas cada 25 días (a) y temperatura mínima con isolíneas cada 10 días (b) sobre las estaciones de referencia.

sobre la temperatura máxima se observa la mayor señal en este ancho de banda entre fines del otoño y el inicio del invierno en el centro de Argentina y sur de Brasil, mientras que sobre la Patagonia la mayor amplitud se registra en la primavera. Para la temperatura mínima, el comportamiento de esta señal es más homogéneo, observándose la mayor frecuencia de días con señal en un entorno de 15 días centrado en el día 180, día aproximado en que se produce el mínimo anual de temperatura. Este resultado se asocia directamente a la influencia que tiene la nubosidad sobre la temperatura máxima, mientras que la temperatura mínima parece tener una mayor independencia sobre este efecto. Por esto la temperatura mínima puede reflejar en mejor medida las propiedades termodinámicas del aire y por consiguiente la magnitud de las irrupciones cálidas/frías.

5.2 Variación temporal de estimación espectral wavelet a escala intraestacional

El principal modo de oscilación a escala intraestacional (30 a 90 días) es el que se observa con períodos entre 30 y 60 días (Ghil and Mo 1991b, Madden and Julian, 1994). Este modo que se observa sobre diferentes variables del sistema climático está forzado por diferentes patrones de circulación persistentes los cuales responden a cambios en las condiciones de borde del sistema. Sin embargo este tipo de oscilaciones muestra un efecto transiente tanto en la variabilidad estacional como interanual, es decir que un fenómeno de este tipo no evidencia el mismo impacto sobre cada variable tanto en magnitud como en duración durante todos los años. Dado que se observa una señal de este tipo sobre las temperaturas extremas diarias en el sudeste de Sudamérica, en la siguiente sección se discute sobre la variabilidad interanual de este tipo de oscilaciones.

En las figuras 5.9 y 5.10 se muestran las marchas interanuales de la cantidad de días por año con cuasi-periodicidades de entre 33 y 55 días con densidad espectral wavelet significativa al 95% para las anomalías temperatura máxima y mínima. Además esta información se detalla en las tablas I-1 a I-4 del anexo I. A partir de esta información se desprende que la aparición de ciclos de entre 30 y 60 días muestra en general una persistencia de entre 30 a 200 días. Es decir que las transiciones entre eventos cálidos y fríos se suceden con el período citado durante un mes y puede persistir hasta por tres estaciones, generalmente centrada en el invierno.

En cuanto a la frecuencia interanual en que se evidencian este tipo de oscilaciones, se observa que este fenómeno tiene una probabilidad de ocurrencia de entre 30 y 50% según la estación analizada. Así mismo, se observa que existe una mayor tendencia a aparecer en intervalos de 1-2 años, menos frecuentemente en intervalos de 4-8 años y excepcionalmente cada 12 años. Dada esta variabilidad se observan algunos períodos preferenciales donde esta perturbación intraestacional es más frecuente y posee mayor amplitud (figura 5.11). Durante la década de 1950, 1970 y durante fines de 1980 la amplitud máxima de este modo de oscilación supera los 3° C.

Otro resultado relevante que surge del análisis, es que no existe en general una coherencia aparente sobre la ocurrencia de ondas cuasi-periódicas entre la temperatura máxima y

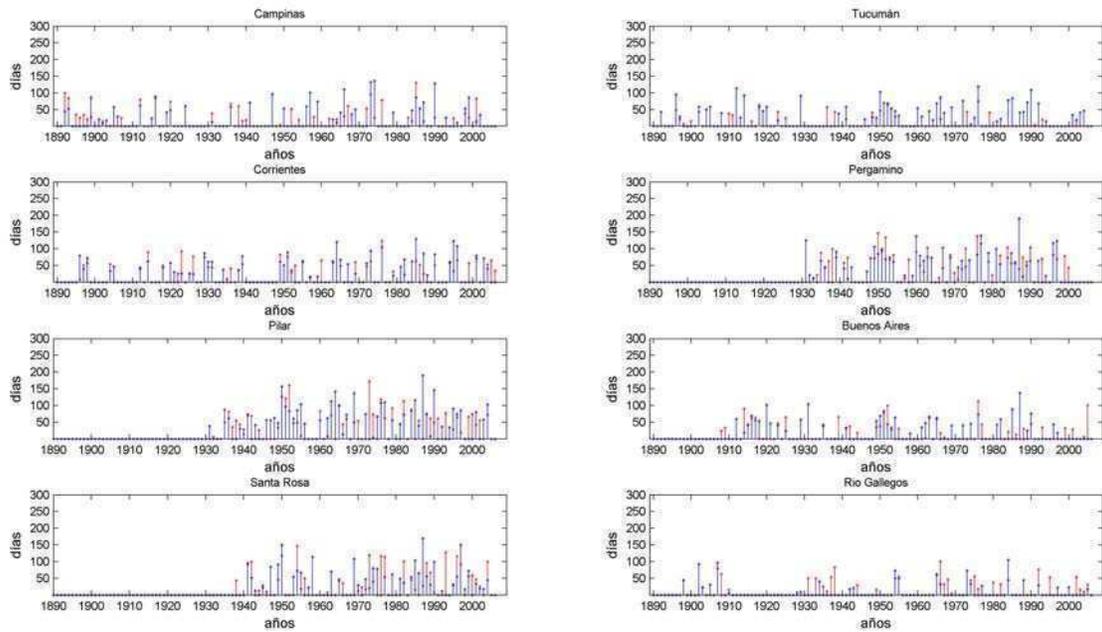


Figura 5.9. Cantidad de días por año con cuasi-periodicidades de 33 días con densidad espectral wavelet significativa al 95% para la temperatura máxima (rojo) y mínima (azul) sobre las estaciones de referencia.

mínima. Esto implica que los diferentes procesos físicos que actúan sobre la nubosidad y precipitación y sobre las irrupciones de aire frío o cálido tienden a manifestarse de distinta forma. Sin embargo, en algunos casos estas diferencias no se manifiestan y en la mayoría de las estaciones de referencia se observa una homogeneidad en las dos variables. Esta coherencia se observa principalmente durante los años 1954, 1965, 1976, 1984 y 2001.

Por otro lado y al igual de lo mostrado en las secciones anteriores se observa la existencia de una coherencia regional observada por éste tipo de variaciones, con lo que se infiere que los procesos que modulan esta variabilidad son de gran escala atribuibles tanto a irrupciones de aire polar hacia el trópico o sus inversas como persistencia de aire tropical (olas de calor). En la figura 5.12 se muestran los campos asociados a la máxima amplitud (reconstruida según la ecuación (5.3)) que pueden alcanzar las ondas con períodos entre 30 y 60 días. En esta figura se observa una distribución caracterizada por un gradiente meridional con pocas variaciones espaciales con amplitudes de las anomalías de

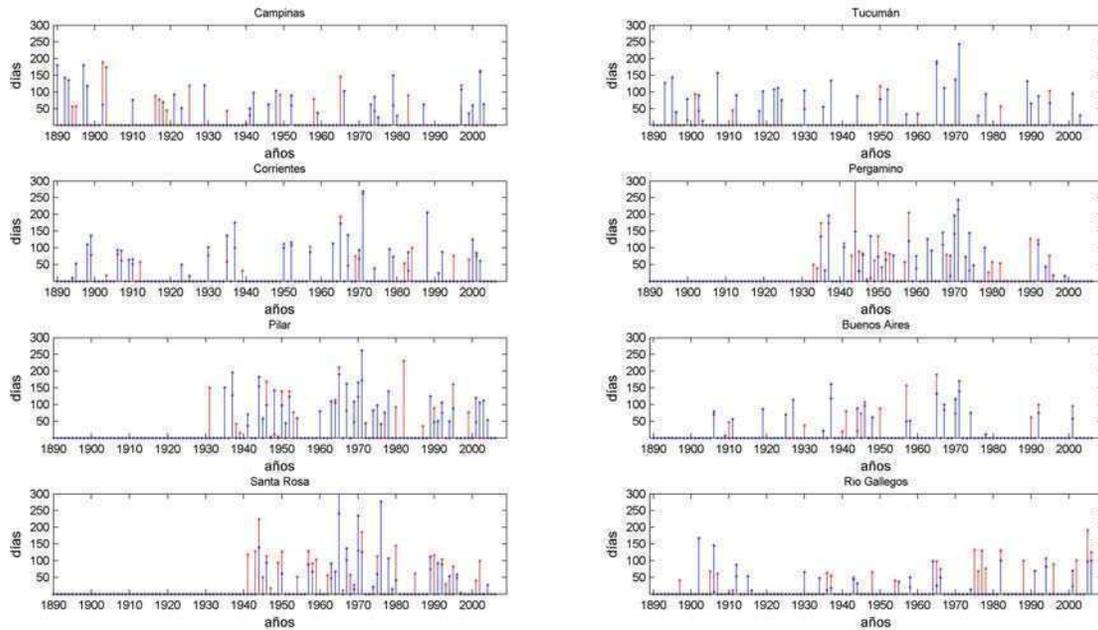


Figura 5.10. Cantidad de días por año con cuasi-periodicidades de 55 días con densidad espectral wavelet significativa al 95% para la Temperatura máxima (rojo) y mínima (azul) sobre las estaciones de referencia.

temperatura entre 2 y 3 °C en casi toda la región. La región que presenta mayores diferencias, es la noreste de Argentina y principalmente es el sur de Brasil, donde se observan amplitudes máximas cercanas a 5 °C.

Si consideramos las fechas de ocurrencia de estos máximos, en la figura 5.13 se muestran las isócronas relativas a la ocurrencia de la máxima amplitud de las oscilaciones entre 30 y 60 días sobre la temperatura máxima y mínima. Aquí se observa que para todo el norte y centro de Argentina la mayor señal intraestacional se observó durante la década de 1970, mientras que para el noreste Argentino y sur de Brasil este máximo se dio durante la década de 1990. Estos resultados ratifican la homogeneidad regional en cuanto a la ocurrencia del modo intraestacional. Además se destaca el comportamiento diferenciado que muestra el Noreste de Argentina y el sur de Brasil, región donde el impacto del ENOS (El Niño-Oscilación del Sur), principalmente sobre la precipitación es mayor.

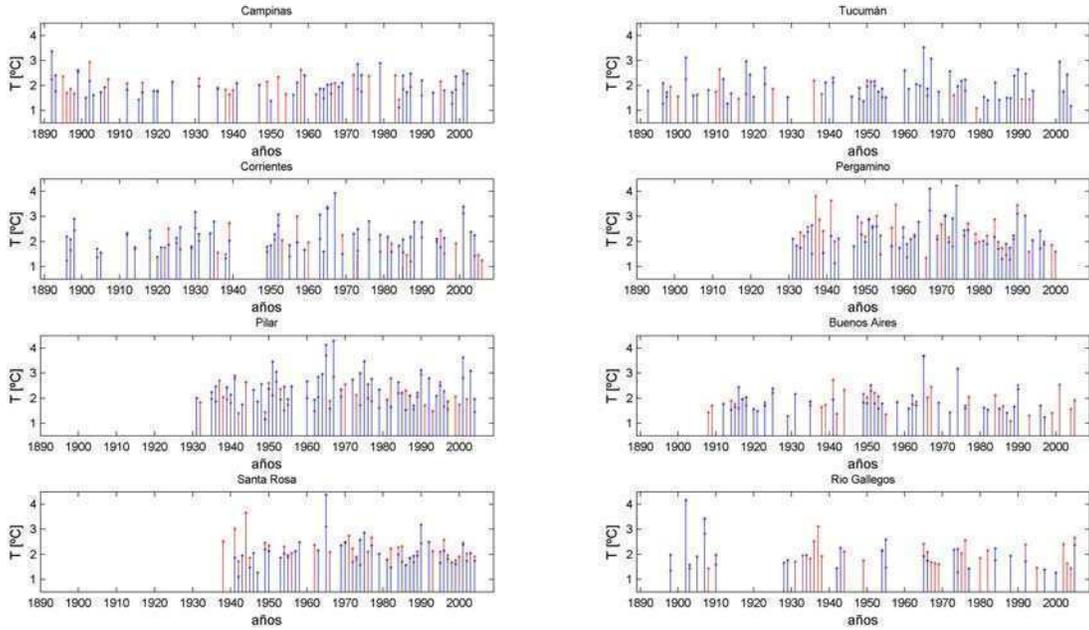


Figura 5.11. Amplitud máxima anual asociada a las cuasi-periodicidades entre 30-60 días con densidad espectral wavelet significativa al 95% para la temperatura máxima (rojo) y mínima (azul) sobre las estaciones de referencia.

5.3 Principales modos de oscilación en la escala intraestacional.

El reconocimiento de patrones o modos de oscilación, en este caso, es posible mediante la selección o extracción de características de la información analizada. El objetivo principal de las técnicas de clasificación es obtener una reducción de la dimensionalidad del espacio original al que pertenecen los datos originales. Por lo tanto el resultado esperado es el de poder representar mediante un conjunto efectivo y reducido las características principales de las series tratando de retener la mayor cantidad de información. Así mismo y dado que los métodos de clasificación contienen algún grado de subjetividad en las siguientes secciones se detallan los resultados sobre la clasificación de los modos de oscilación intraestacional sobre la temperatura diaria mediante dos métodos. Las metodologías usadas refieren al análisis de componentes principales y al análisis de cluster detalladas en el capítulo

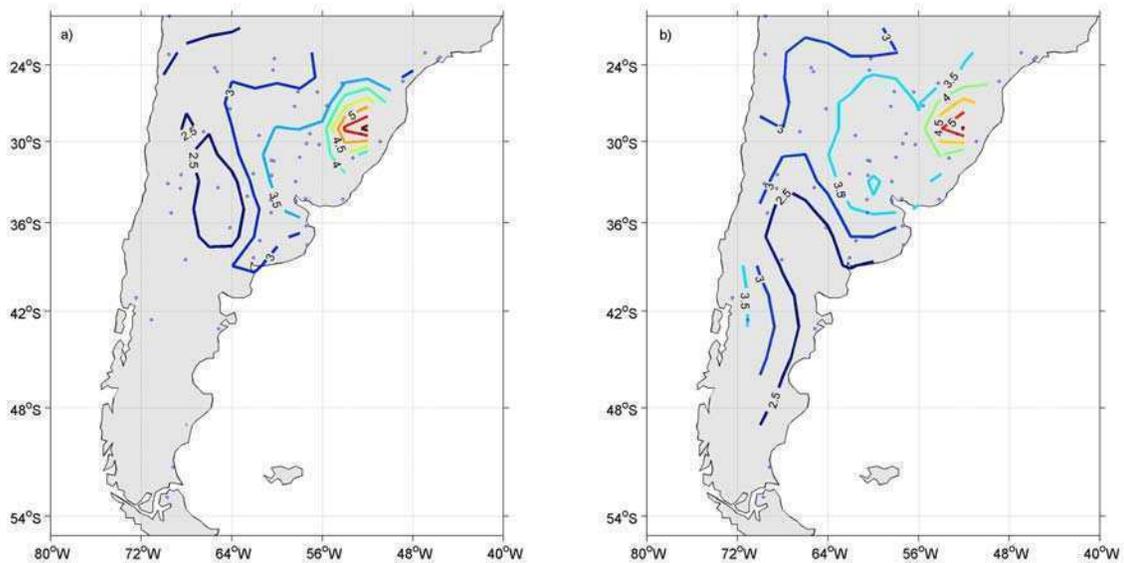


Figura 5.12. Distribución espacial de la máxima amplitud (°C) de las oscilaciones entre 30 y 60 días para la temperatura máxima (a) y mínima (b).

2. Estos métodos fueron aplicados sobre las series de anomalías de temperatura reconstruidas utilizando la ecuación (5.3) en el ancho de banda entre 30 y 60 días para los años en que se registraron valores de densidad espectral significativa en esta región del espectro.

5.3.1 Clasificación mediante componentes principales.

En la figura 5.14 se muestra la varianza explicada por cada componente principal (CP) sobre la reconstrucción de las anomalías de Temperatura máxima y mínima en el ancho de banda entre 30 y 60 días. Aquí se observa que un comportamiento regional homogéneo para las dos variables donde en general la primera componente explica entre el 14 y 18 % de la varianza total, siendo sobre la temperatura mínima donde los patrones de oscilación intraestacional son mayormente identificables. Además, si se consideran las tres primeras CP se tiene que en general estas explican más del 40% en toda la región. Teniendo en

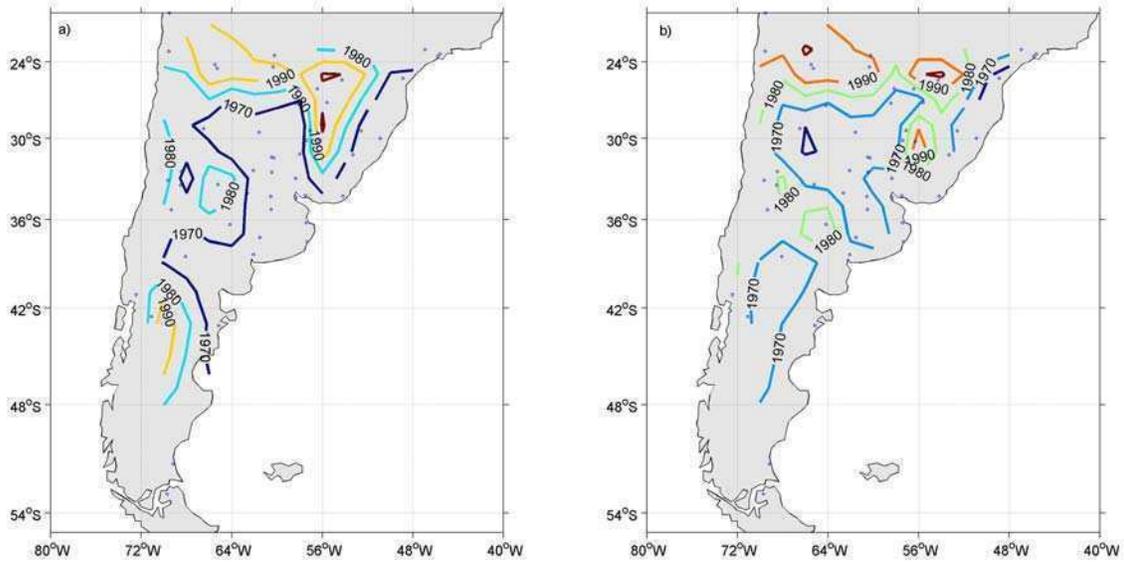


Figura 5.13. Isócronas (años) de la máxima amplitud de las oscilaciones entre 30 y 60 días para la temperatura máxima (a) y mínima (b).

cuenta las características transitorias de estas ondas, este valor de varianza explicada permite suponer la existencia de algún patrón estable que permita identificar un modelo conceptual sobre las características generales de este modo de oscilación.

En la figura 5.15 se muestra la primera componente principal sobre las estaciones de referencia. Aquí se observa nuevamente una gran coherencia regional, donde el patrón parece ser el mismo para todas las estaciones. Este modo se caracteriza por el aumento de la señal intraestacional durante el invierno tanto para la temperatura máxima como mínima. En general para las dos variables se observa que el inicio de esta señal está asociado a una irrupción cálida (fría) de aire intensa seguida treinta días después por una irrupción fría (cálida) de gran intensidad. Seguido a esto, durante el mes de julio se observa una irrupción calida (fría) para finalmente aproximadamente 30 días después registrarse otra irrupción fría (cálida) intensa. Antes y después de este período la señal intraestacional tiende a ser incoherente y a tener amplitudes despreciables.

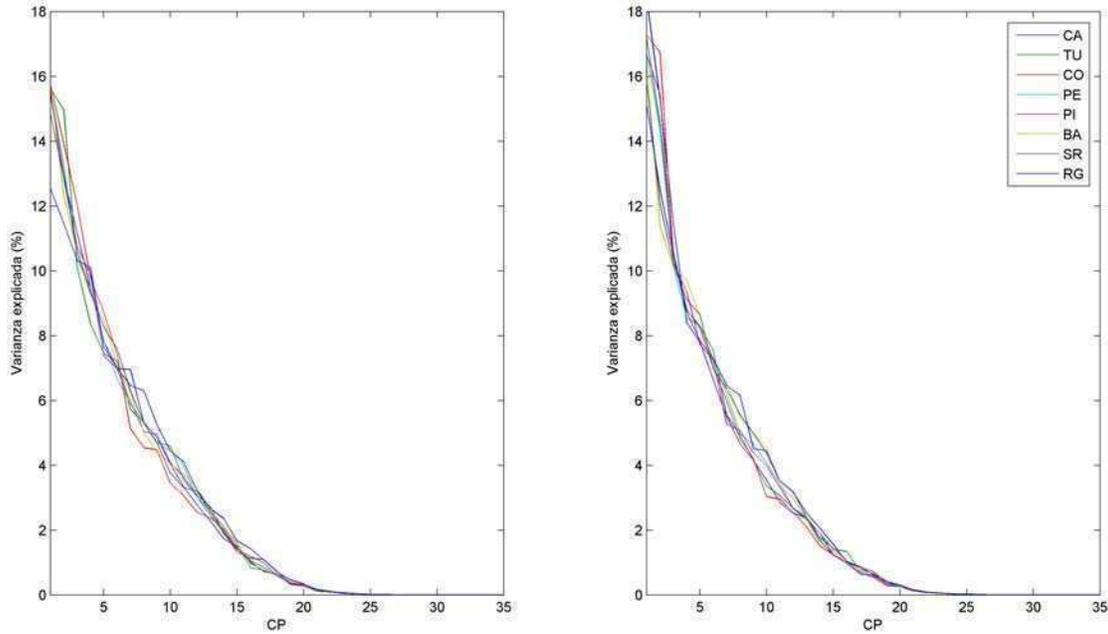


Figura 5.14. Varianza explicada por componente principal (CP) para la clasificación sobre la reconstrucción de las anomalías de temperatura máxima (a) y mínima (b) en el ancho de banda entre 30 y 60 días.

El modelo descrito anteriormente es el principal modo observado y es el resultado de la modulación en la banda intraestacional de la temperatura. Este resultado permite identificar las épocas del año y magnitud en que se esperan las máximas irrupciones tanto cálidas o frías en la región. En Campinas y Corrientes esta descripción es válida pero se observa con un lag de 15 días donde la primera irrupción cálida se observa en los primeros días de junio. Si analizamos la segunda componente principal (figura 5.16) se observa que para la temperatura máxima ya no existe una coherencia regional tan marcada como para la 1° CP. Sin embargo se identifica una irrupción fría (cálida) a mediados de junio seguida 30 días después por una irrupción cálida (fría). Finalmente se registra otra irrupción fría (cálida) a mediados de agosto. Por otro lado, para la temperatura mínima se observa una señal más homogénea sobre la 2° CP. Aquí el modelo regional se puede describir con irrupciones frías intensas durante los meses de abril, junio y agosto, mientras que las cálidas se dan en mayo y julio.

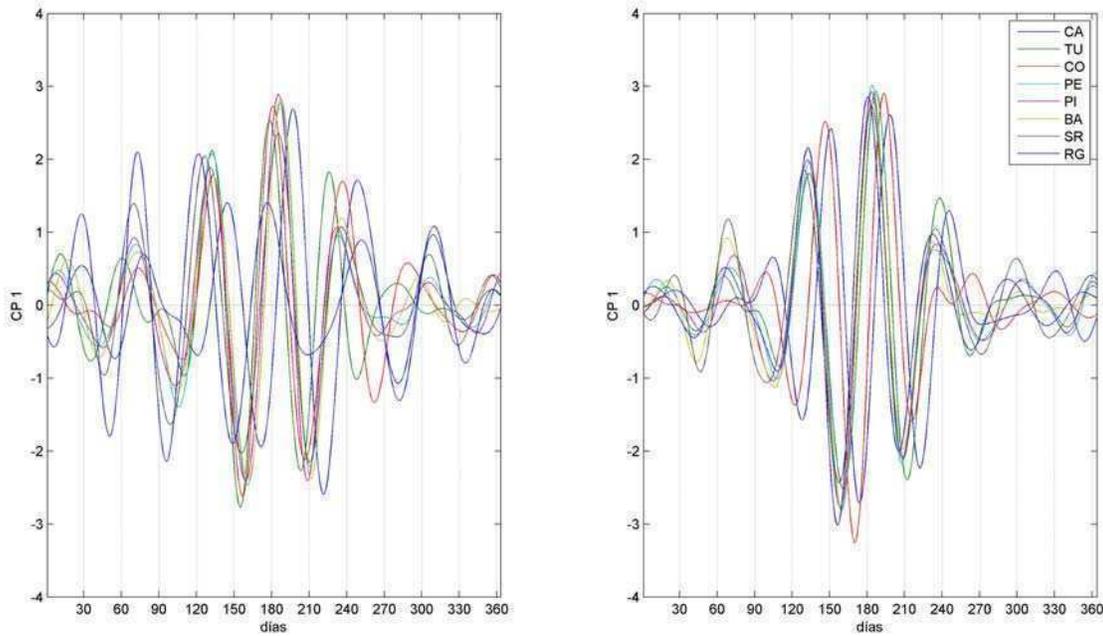


Figura 5.15. CP 1 para la temperatura máxima (a) y mínima (b) para las estaciones de referencia.

La información contenida en las primeras dos componentes principales describe el efecto de los procesos no lineales sobre las propiedades térmicas del aire en superficie en la región. Estos procesos, en general de gran escala, bajo ciertas condiciones tienden a favorecer el transporte meridional de calor en forma de cuasi-periodicidades que persisten por un lapso de entre una a tres estaciones del año.

5.3.2 Clasificación mediante análisis de cluster

Con el objetivo de aumentar la descripción sobre los distintos modos de oscilación que se observan sobre la temperatura en escala intraestacional, en la siguiente sección se describe la clasificación de estas cuasi-periodicidades mediante análisis de cluster K-means (ver datos y métodos). A partir de esta clasificación se pretende relacionar el impacto de los diferentes modos en la escala 30-60 días sobre las anomalías de temperatura máxima y mínima para cada región climática representada por una estación de referencia. Así mismo,

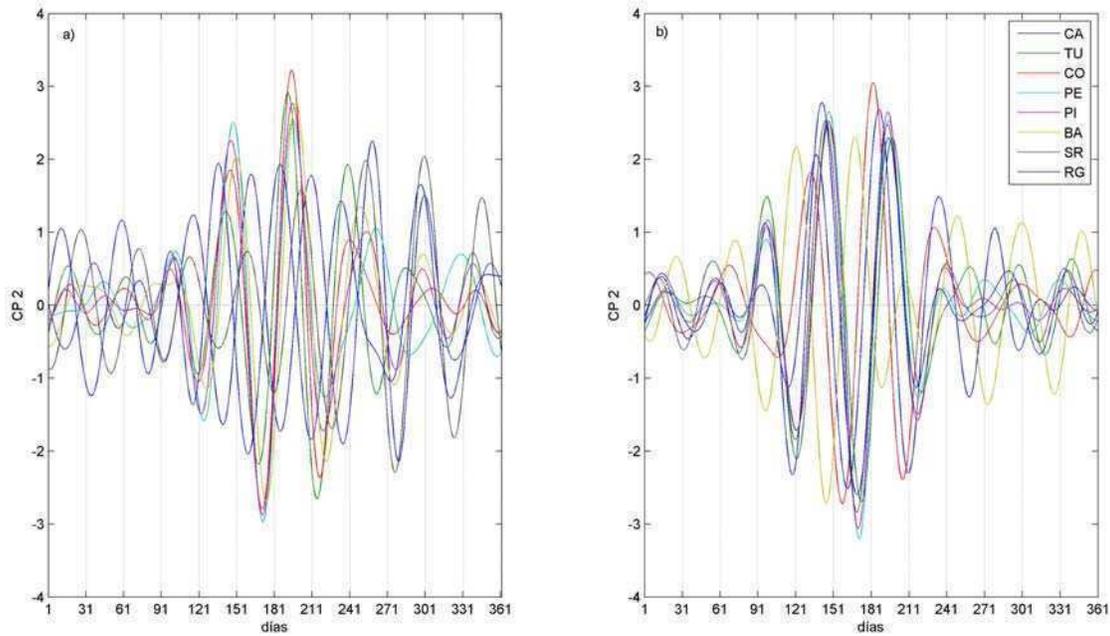


Figura 5.16. CP 2 para la temperatura máxima (a) y mínima (b) para las estaciones de referencia.

esta información detalla las fechas preferenciales de ocurrencia e intensidad de las irrupciones de aire más intensas debida a efectos dentro de la escala intraestacional.

Si bien la cantidad de grupos (K) a elegir es definida de manera subjetiva y esta condicionada a los fenómenos físicos que se desean detallar, existen algunos métodos que permiten inferir sobre cual es la cantidad de grupos eficiente para la clasificación. En general estos métodos definen la cantidad de grupos óptima a partir de algún umbral donde una mayor síntesis de los datos originales no agrega una cantidad significativa de información. En este trabajo de tesis se propone el índice de Hartigan (HI) (ver datos y métodos), donde los menores valores del índice implican una buena partición y la cantidad de grupos K es óptima a partir que HI tiende a estabilizarse. En la figura 5.17 se muestra el HI para la clasificación sobre la reconstrucción de las anomalías de temperatura en el espectro entre 30 y 60 días. En esta figura se observa que hay una mejora en la clasificación (disminución del índice) para los primeros 5-6 valores de K. A partir de esta cantidad de grupos el índice tiende a estabilizarse y no se observa un aumento significativo de la

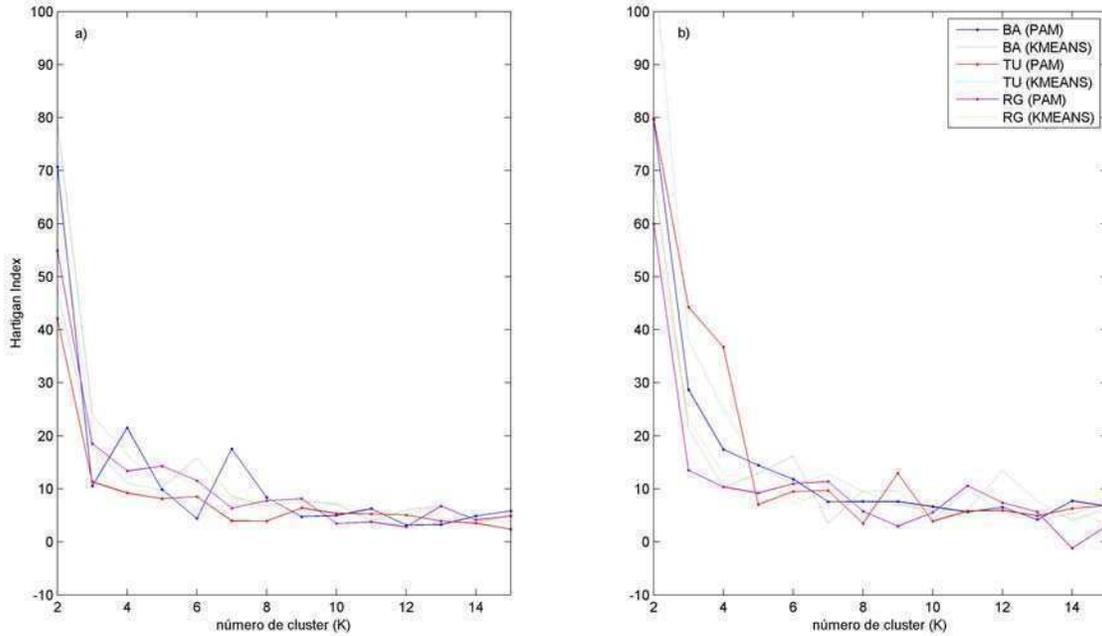


Figura 5.17. Índice de Harting para determinar la cantidad de cluster (k) óptima para la clasificación sobre la reconstrucción de las anomalías de temperatura máxima (a) y mínima (b) en el ancho de banda entre 30 y 60 días.

información al introducir más grupos. Este comportamiento se observa tanto para la temperatura máxima como para la mínima con lo cual se describe el análisis a partir de la clasificación de seis grupos.

En general para todas las estaciones de referencia (figuras 5.18 a 5.33) se tiene que los grupos con mayor cantidad de miembros muestran un comportamiento similar a las primeras dos componentes principales descritas en la sección anterior. Esto es, la mayor señal intraestacional se registra en el invierno asociado a dos irrupciones frías y dos cálidas centradas en la época en que se registra el mínimo de temperatura de acuerdo a la onda anual. En relación a estos resultados, en Zha et al (2001) y Ding and Xiaofeng (2004) se muestra que la solución de K means, definida por los parámetros de su estimación (el subespacio especificado por los centroides) es comparable y bajo algunas condiciones idénticas al subespacio definido por las direcciones de las componentes principales.

Además de estos dos modos de oscilación principales que manifiestan su máxima amplitud durante el invierno también existen otros dos modos que se manifiestan de manera similar. El primero comienza a manifestarse durante el otoño para persistir hasta los primeros meses del invierno como el que se observa para el grupo $K=1$ y su inversa $K=2$ sobre la temperatura mínima en Tucumán (Figura 5.21). El impacto de este modo sobre las anomalías de temperatura se manifiesta inicialmente con un período cálido (frío) durante el mes de abril seguido por un período frío (cálido) durante el mes de mayo para finalmente manifestar un comienzo del invierno con anomalías cálidas (frías). Esto implica que bajo estas condiciones existe la presencia de precursores durante los primeros meses del otoño que permitirían prever un comportamiento del mismo signo durante el comienzo del invierno.

El otro modo representa el comportamiento de las anomalías con mayor señal intraestacional sobre la temperatura durante el fin del invierno y la primavera (por ejemplo en $K=5$ de la figura 5.21). En esta situación se evidencia que al final del invierno (principalmente durante fines de julio y principio de agosto) el modo intraestacional crece en amplitud para manifestarse entre 30 y 50 días después otro período persistente de anomalías de temperatura del mismo signo. En este caso, los procesos persistentes que definen las anomalías de temperatura de la primavera, se encuentran desfasados respecto al modo principal de oscilación intraestacional en casi una estación. Así mismo, cabe mencionar que para todos los modos descriptos, cuando el modo intraestacional evidencia amplitudes significativas, el producto de estas anomalías define el valor medio de temperatura de toda una estación del año.

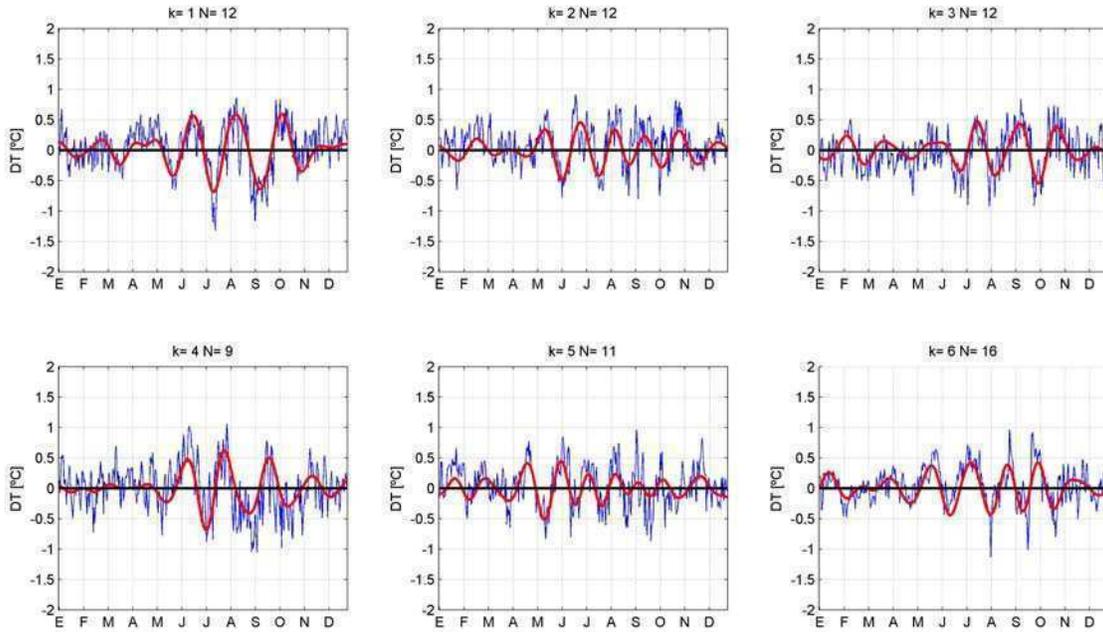


Figura 5.18. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura máxima en Campinas.

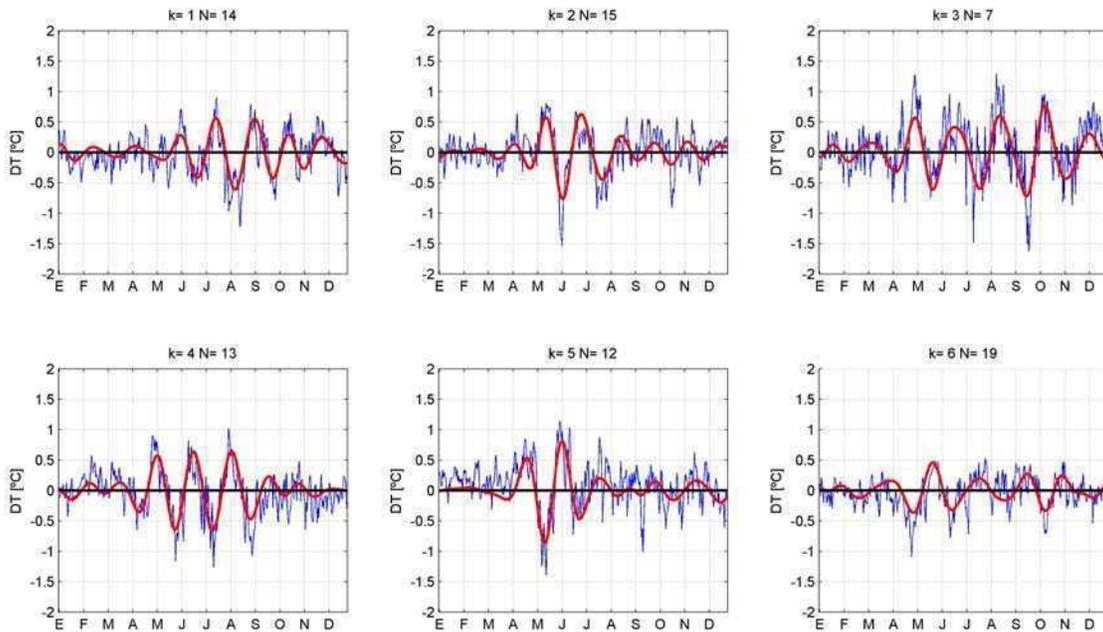


Figura 5.19. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura mínima en Campinas.

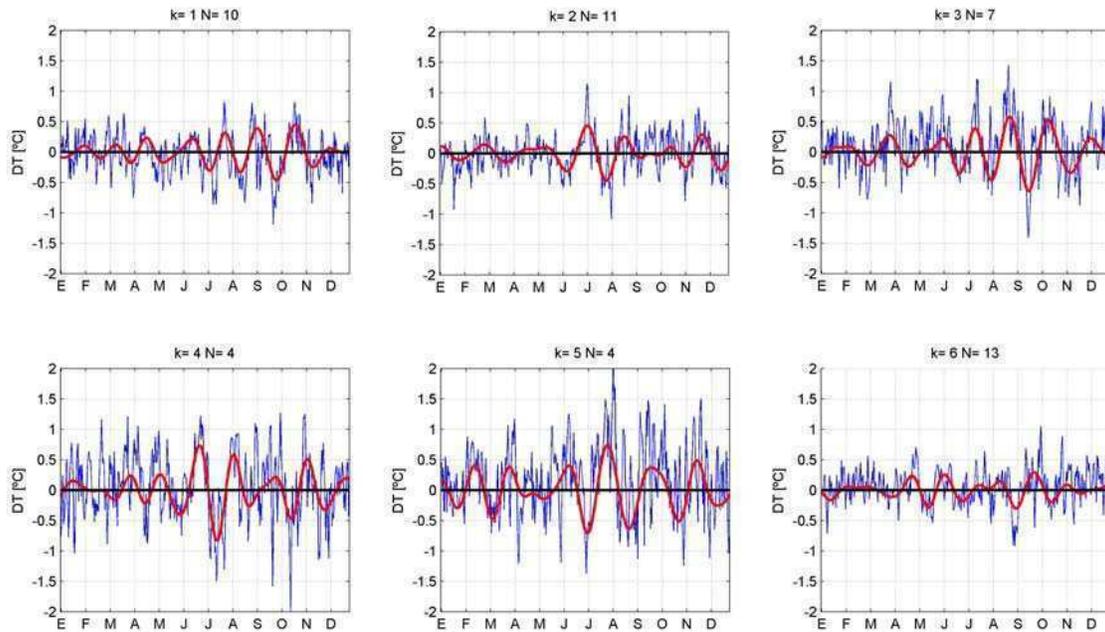


Figura 5.20. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura máxima en S. M. de Tucumán.

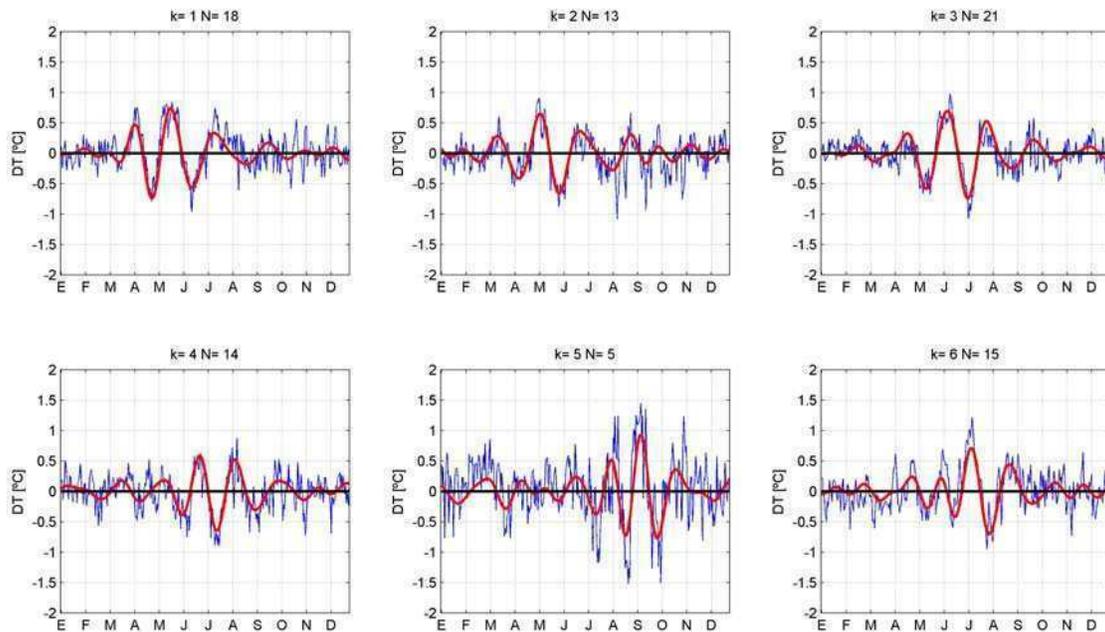


Figura 5.21. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura mínima en S. M. de Tucumán.

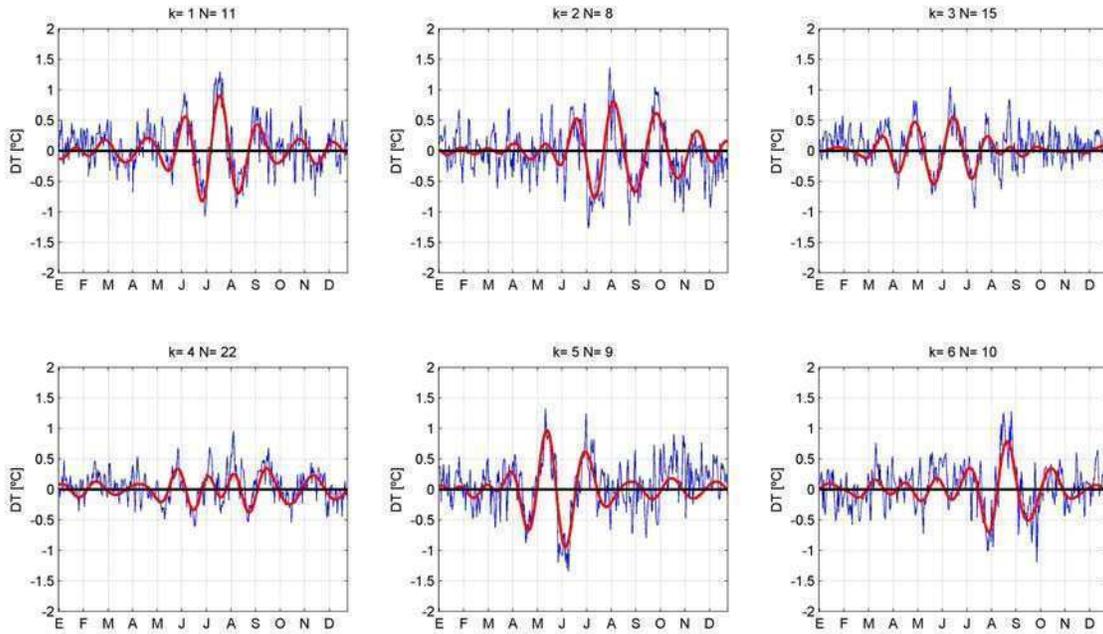


Figura 5.22. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura máxima en Corrientes.

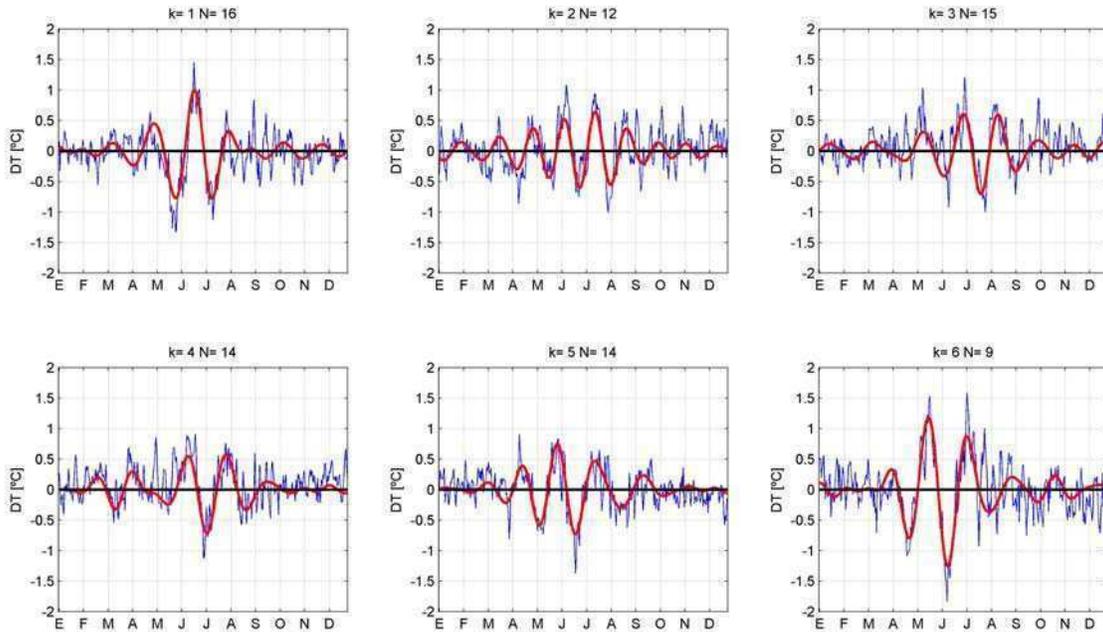


Figura 5.23. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura mínima en Corrientes.

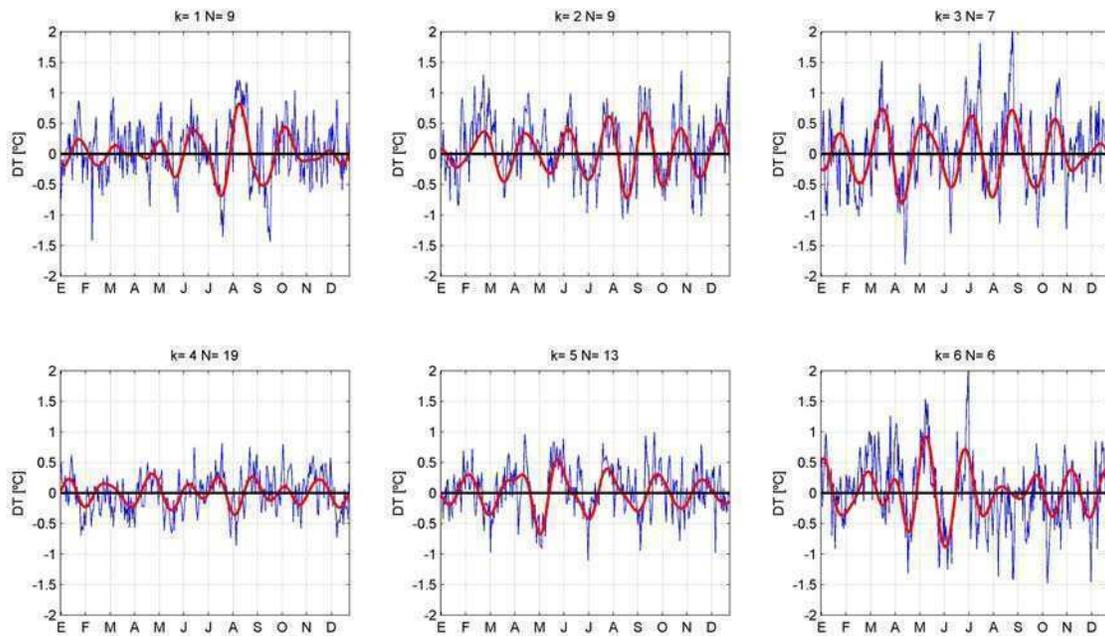


Figura 5.24. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura máxima en Pergamino.

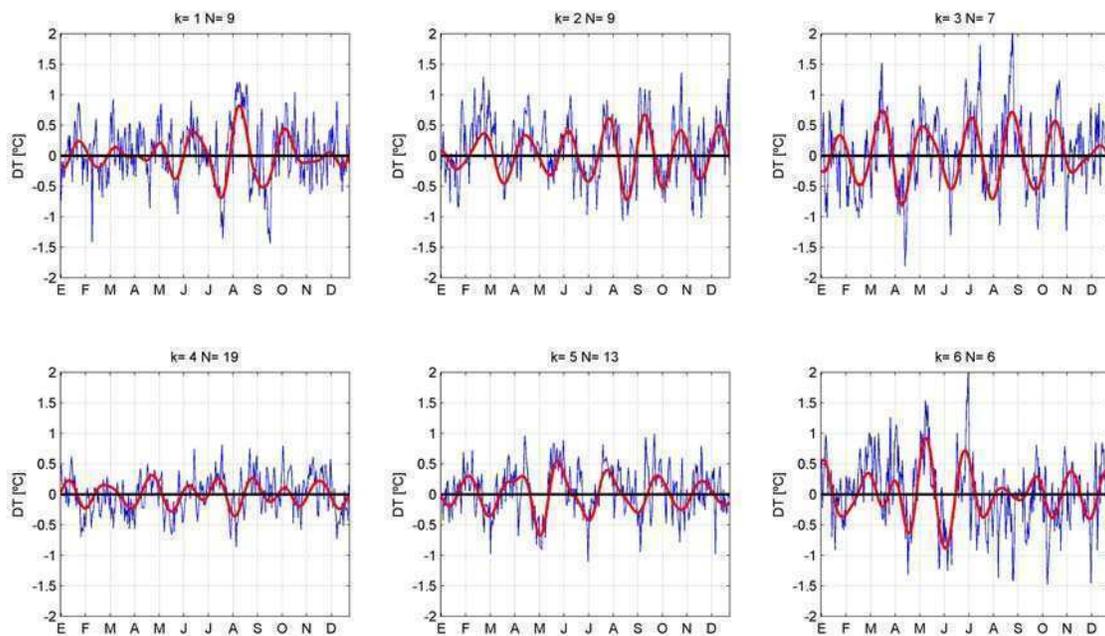


Figura 5.25. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura mínima en Pergamino.

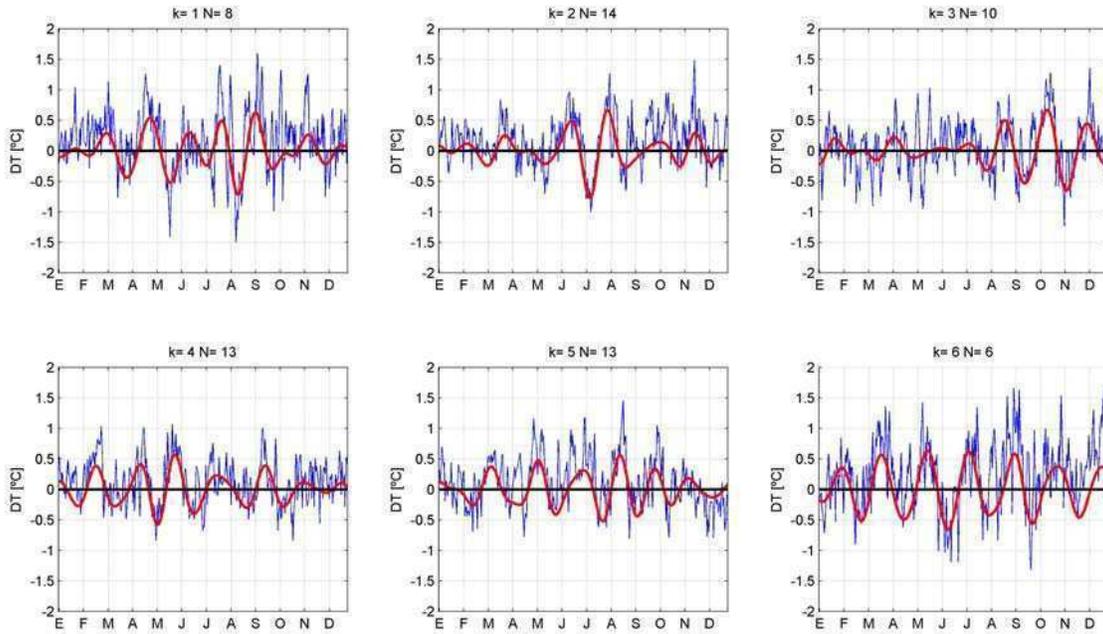


Figura 5.26. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura máxima en Pilar.

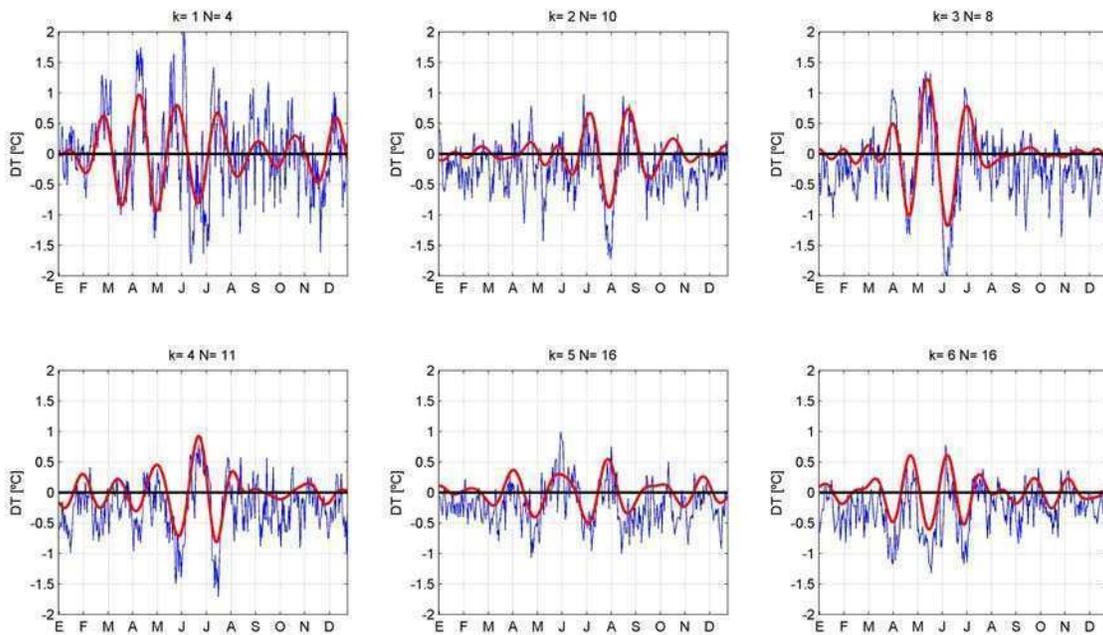


Figura 5.27. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura mínima en Pilar.

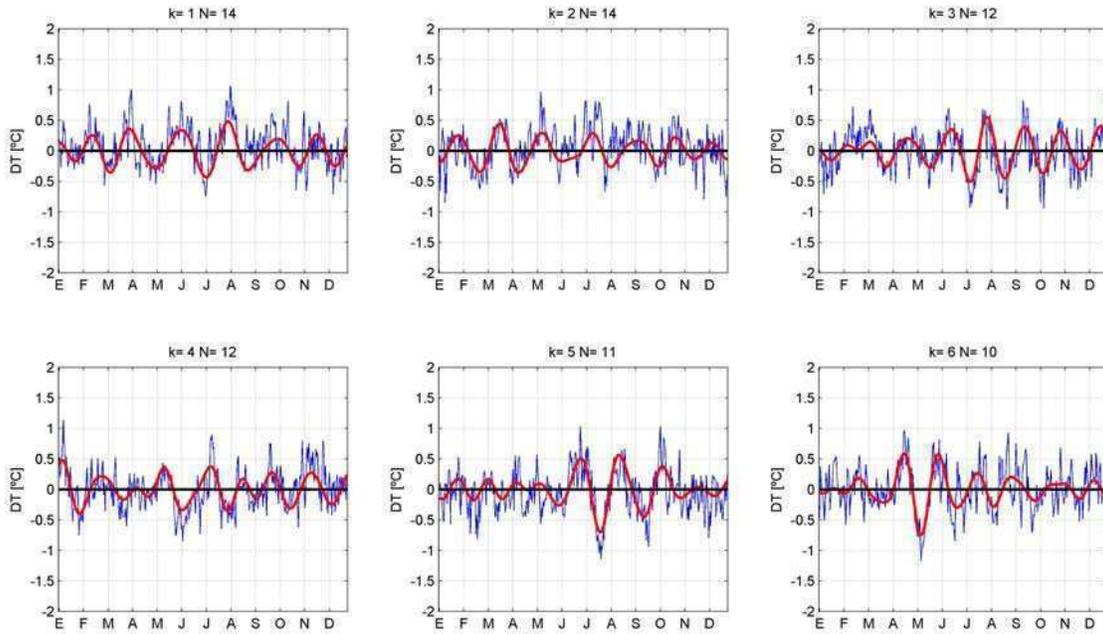


Figura 5.28. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura máxima en Buenos Aires.

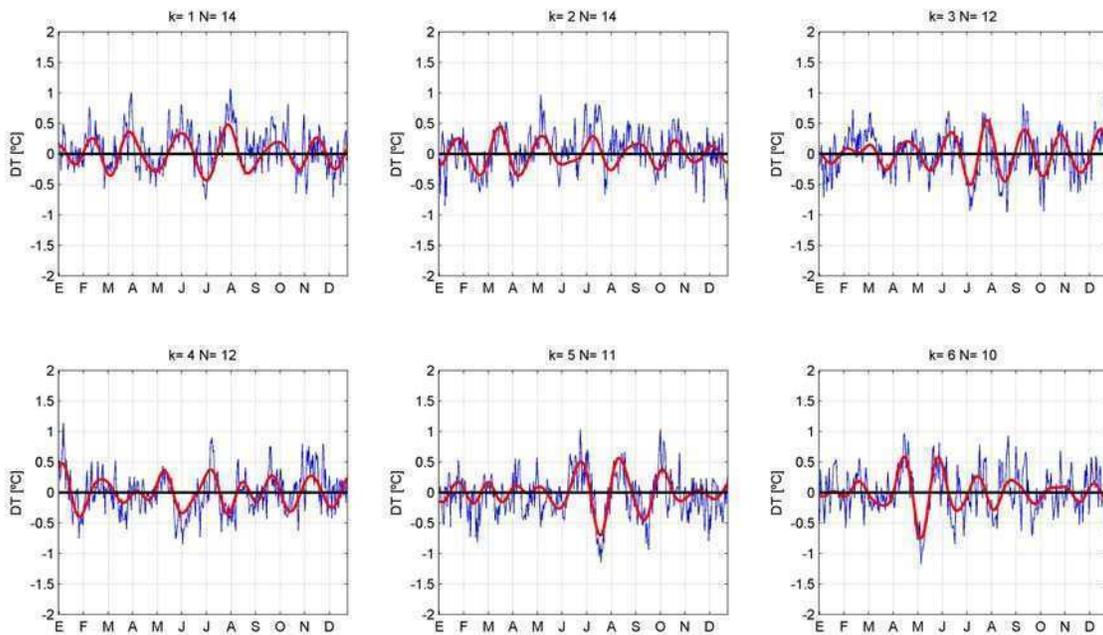


Figura 5.29. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura mínima en Buenos Aires.

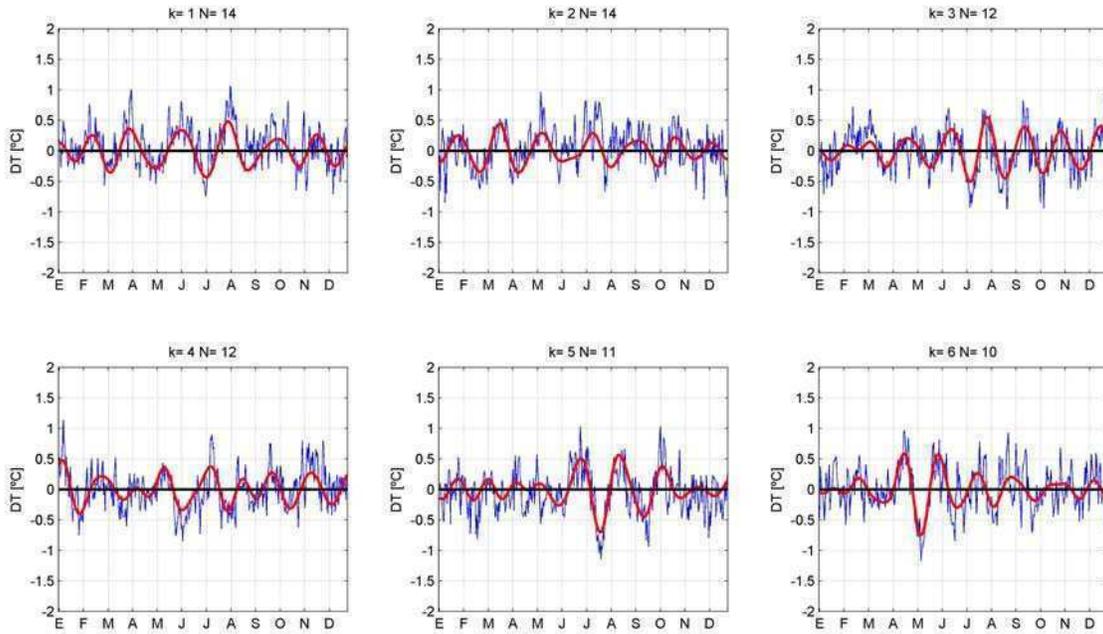


Figura 5.30. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura máxima en Santa Rosa.

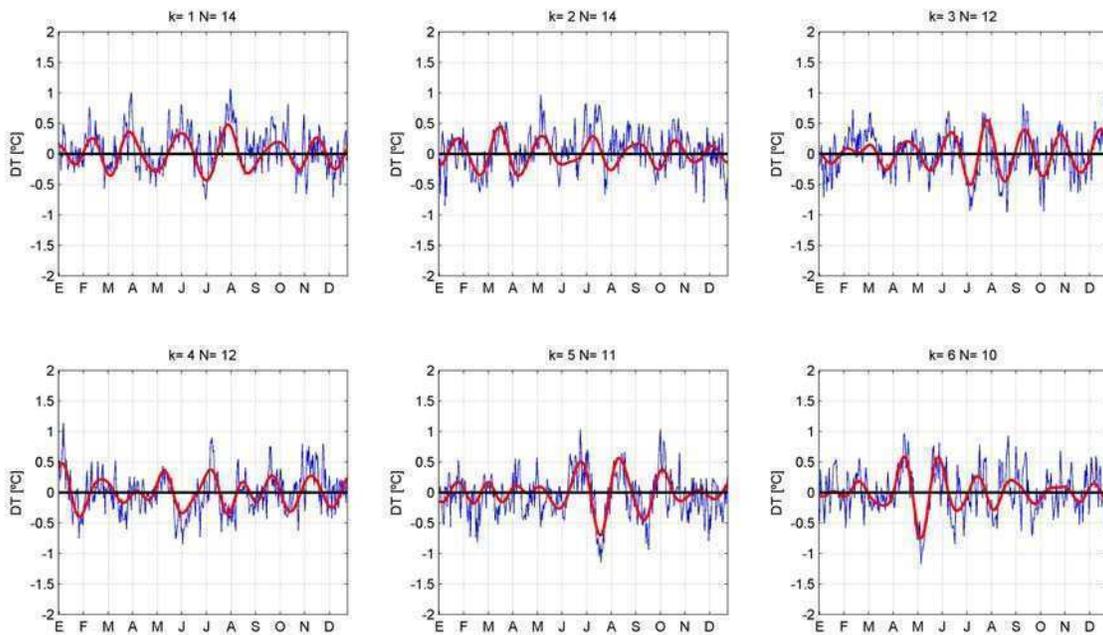


Figura 5.31. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura mínima en Santa Rosa.

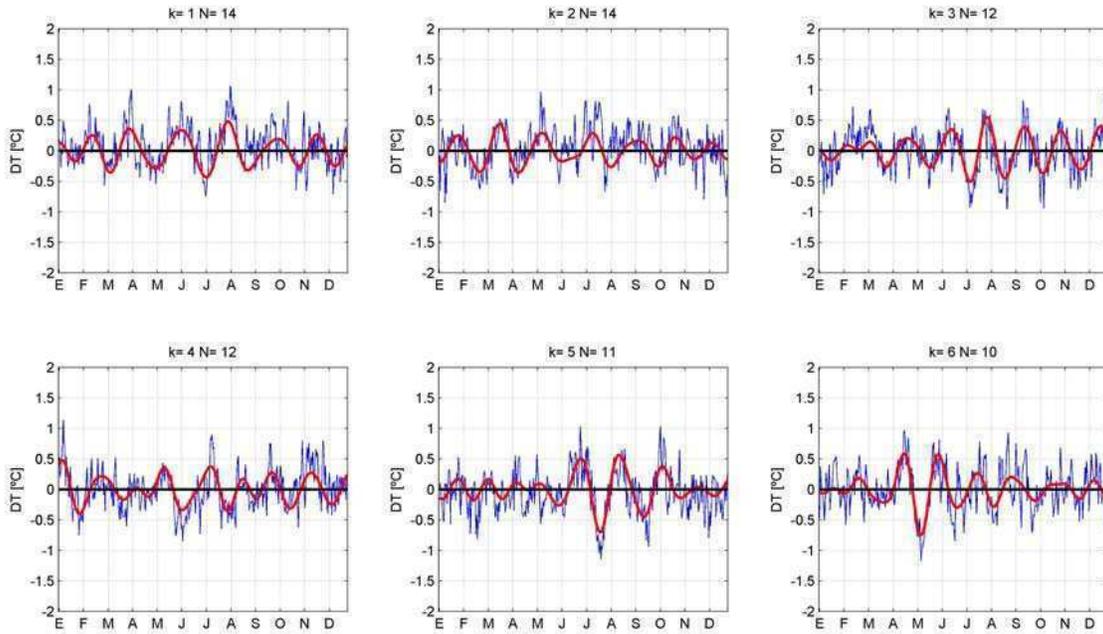


Figura 5.32. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura máxima en Río Gallegos.

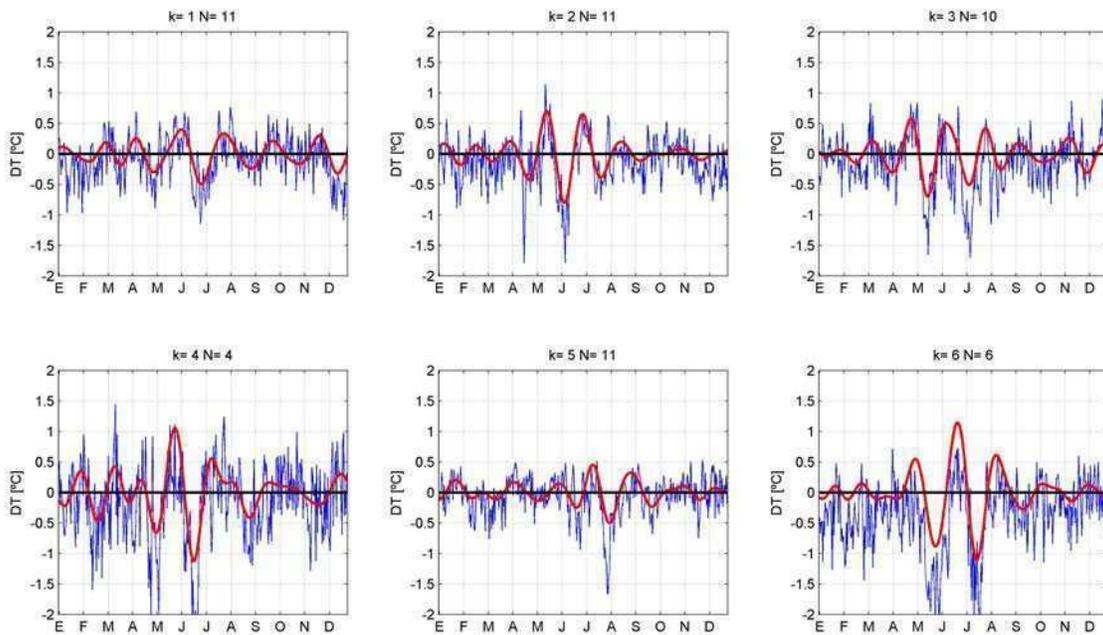


Figura 5.33. Centroides asociados a los seis grupos (K) relativos a la reconstrucción de las anomalías en la escala intraestacional (rojo) y el promedio del conjunto de miembros (N) de cada grupo (azul) sobre la temperatura mínima en Río Gallegos.

5.4 Relación entre la variabilidad intraestacional de la temperatura y la oscilación de Madden-Julian

La oscilación de Madden-Julian (MJO) es el modo dominante en la variabilidad intraestacional en la atmósfera tropical. Esta oscilación es la responsable de la variabilidad en estas regiones y su influencia alcanza a importantes parámetros atmosféricos y oceánicos. El período típico del ciclo MJO es aproximadamente de 30-60 días (Madden and Julian, 1971, 1972; Madden and Julian, 1994; Zhang, 2005). La influencia de las anomalías de circulación atmosférica se extiende desde la región de directa influencia de éste fenómeno, afectando los patrones de circulación globales. Se han desarrollado diversos estudios que relacionan la interacción entre variaciones dentro de la escala sinóptica y la MJO.

Matthews y Kiladis (1999) investigaron sobre la interacción entre las perturbaciones transientes de alta frecuencia y la convección con la MJO, encontrando evidencias de que la propagación de ondas de alta frecuencia en el Océano Índico pueden ser de relevancia para el comienzo de anomalías convectivas de escala intraestacional. Sobre la interacción trópico-extratropical, Matthews y Meredith, 2004 y Zhou y Miller, 2005, encontraron que la variabilidad del modo anular meridional atmosférico en escala intraestacional muestra relación con variabilidad atmosférica relacionada con la MJO durante el invierno meridional.

Por otro lado, en un análisis sobre la relación de la MJO con la variabilidad de la temperatura Vecchi y Bond, 2004 encontraron una señal estadística significativa y espacial coherente entre la variabilidad atmosférica en altas latitudes y la variabilidad convectiva intertropical en escala intraestacional durante el invierno del Hemisferio Norte, mediante la cual se infiere la conexión entre la MJO con variaciones de la temperatura en superficie en altas latitudes a través de los efectos que la primera induce sobre humedad y anomalías de altura geopotencial en la tropósfera media. Estos resultados concuerdan con lo hallado por Higgins and Mo, 1997; Mo and Higgins, 1998; Jones, 2000, entre otros.

Por otra parte Minetti y Vargas (1997b) mostraron la existencia de una modulación en las fluctuaciones intraestacionales de las anomalías de temperatura en el trópico argentino debidas a las diferentes fases del ENSO. Dentro de la escala de la oscilación MJO y la del ciclo índice de 19 días, se observan ondas atmosféricas muy importantes en su amplitud y

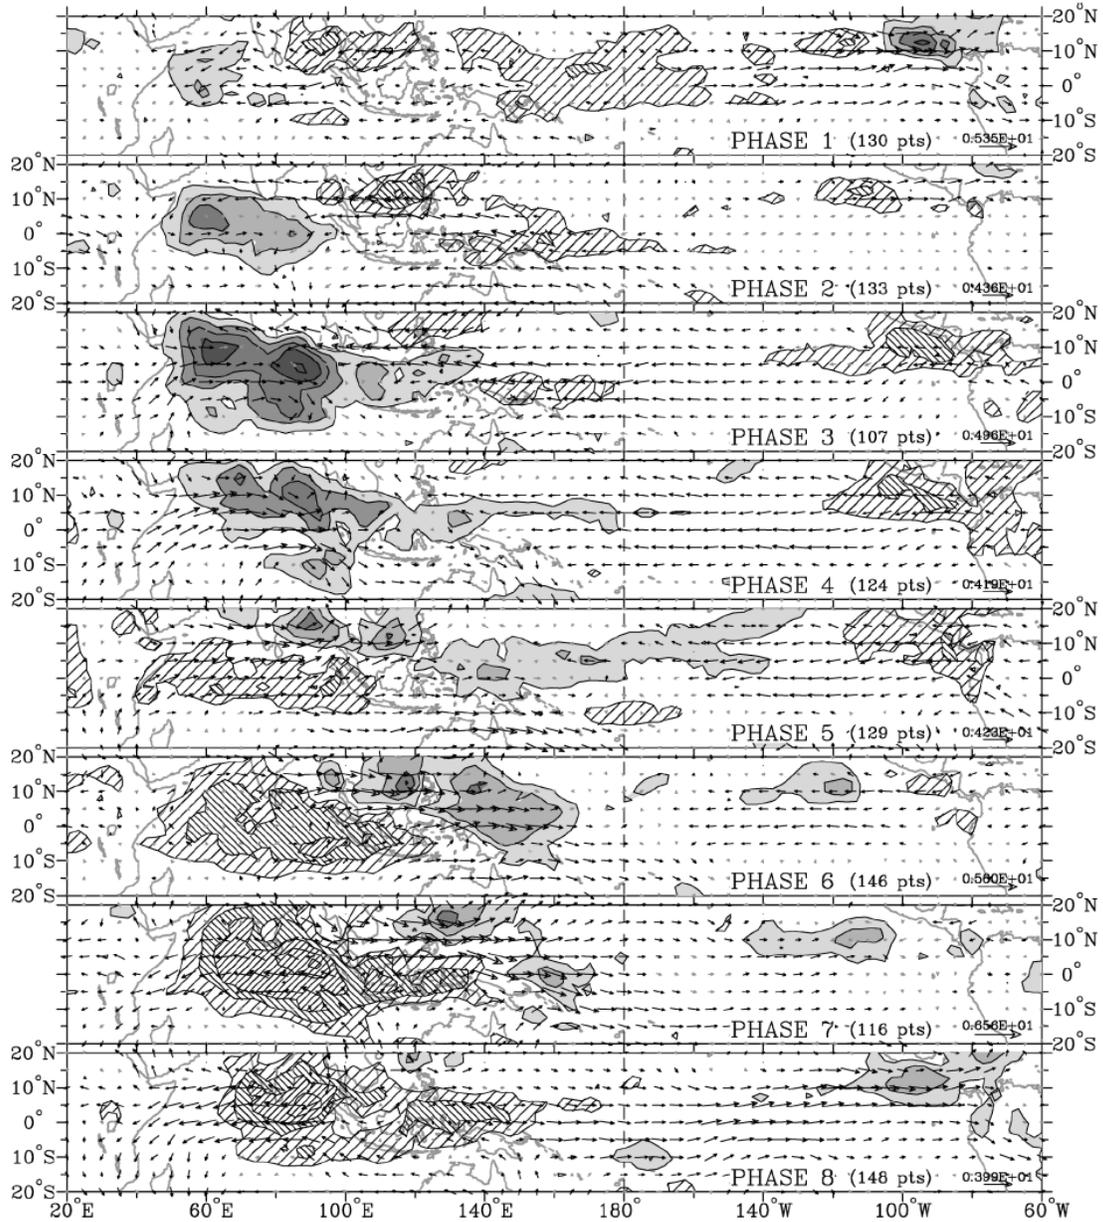


Figura 5.34. Campos medios de OLR y anomalías del vector viento en 850 hPa para ocho fases de MJO durante los meses de mayo y junio (MJ). Áreas sombreadas denotan anomalías de OLR negativas, mientras que las áreas rayadas denotan anomalías de OLR positivas. (Wheeler and Hendon 2004).

persistencia sobre el trópico sudamericano ya usados con fines predictivos en el Norte Argentino desde 1971 (Minetti y Vargas, 2005).

En esta sección se explora sobre el vínculo de las anomalías de temperatura en sur de Sudamérica, con la MJO y su posible impacto en otras variables.

5.4.1 Descripción sobre la representación de la MJO

Para determinar la posible relación entre la MJO y su relación con la circulación atmosférica en el sudeste de Sudamérica se utilizó el índice bivariado RMM1 y RMM2. Este índice se basa en las dos primeras funciones ortogonales empíricas (EOFs) de los campos combinados de velocidad zonal del viento en 850 hPa, 200 hPa y OLR (radiación de onda larga saliente) promediados entre N15°N y 15°S. La proyección de esta información diaria sobre las EOFs con el ciclo anual y variabilidad interanual filtrada produce series temporales de cada componente principal que reproduce la variabilidad de la escala intraestacional. Las dos componentes principales asociadas que conforman el índice multivariado se denominan RMM1 y RMM2. Más detalles sobre la construcción de este índice se puede encontrar en Wheeler and Hendon (2004). Así mismo este índice se encuentra disponible en línea en <http://www.bom.gov.au/bmrc/clfor/cfstaff/matw/maproom/RMM/>.

A partir de esta descripción la MJO se divide en ocho fases, cada una con una duración media de aproximadamente 6 días. En la figura 5.34 (Figura 9 en Wheeler and Hendon, 2004) se muestran los campos medios de OLR y anomalías del viento en 850 hPa para cada fase durante los meses de mayo y junio. Aquí se tiene que la mayor actividad convectiva se observa sobre el Océano Índico entre las fases 1 y 4, registrándose la mayor actividad en la banda intraestacional durante la fase 3. Las fases 5 a 7 se caracterizan por una mayor área de inhibición de la convección sobre el Índico y mayor actividad en el sudeste de Asia y en el Pacífico oriental. Si bien la mayor señal de la MJO se tiene sobre el océano Índico y el Pacífico, también se observan impactos sobre la convección sobre el continente americano. Para las fases 1 y 8 se observan anomalías negativas de OLR sobre América Central y las costas ecuatoriales de Sudamérica, mientras que entre las fases 3 y 5 se observa el efecto contrario en la misma región. Estas perturbaciones producen anomalías del viento en 850 hPa hacia el este de América durante las fases donde se observa la convección activa

sobre el océano Índico. Durante las fases opuestas las anomalías del viento son hacia el oeste

En general la trayectoria de este índice bivariado se representa por círculos alrededor del origen, lo que evidencia una propagación sistemática hacia el este de la MJO. Una mayor amplitud de estos círculos significa fuertes ciclos de la MJO, mientras que para los períodos donde la señal de la MJO es débil, se refleja en el índice como desplazamientos al azar cerca del origen (Wheeler and Hendon 2004).

Para evaluar la relación entre la MJO y la temperatura en superficie en la región se construyeron los campos medios de anomalías de temperatura y precipitación diaria asociados a cada una de las ocho fases en que la MJO muestra una señal coherente. Se consideran los eventos en que la MJO está activa a todos los días en que los valores de la amplitud del índice superó el último tercil. Por otro lado, dado que la mayor señal intraestacional en la región se observa durante la estación fría, los campos medios se calcularon durante el invierno austral, definido por los meses de junio, julio y agosto (JJA). En las figuras 5.35 y 5.36 se muestran los campos medios asociados a la temperatura máxima y mínima. Aquí se observa que las señales de la temperatura asociada con la MJO son espacialmente coherentes. Por ejemplo, para la temperatura mínima se observan anomalías cálidas sobre toda la región norte del dominio para las fases 5 y 6. Por otro lado para las fases 2 y 3 se observa el comportamiento inverso, con anomalías frías en casi toda la región, excepto en el sudeste de Brasil. Cabe destacar que las anomalías observadas, tanto en las fases de calentamiento como de enfriamiento, son estadísticamente significativas (estimada con un test normal) y exceden en casi todas las regiones valores de 1°C , hasta alcanzar incluso valores medios de 4°C .

También se observa un comportamiento coherente entre lo que se observa para la temperatura máxima y la precipitación (figura 5.37), principalmente en el noreste del dominio. En las fases 3 y 5 se observan anomalías positivas de precipitación en el centro este de la región, mientras que se tienen anomalías negativas en la Patagonia y Andes centrales. Las fases 1, 4 y 7 se caracterizan por el comportamiento opuesto con déficit de precipitación en el sudeste de Brasil y noreste de Argentina. Además se destaca para la fase 1 excesos en la Patagonia y cordillera central.

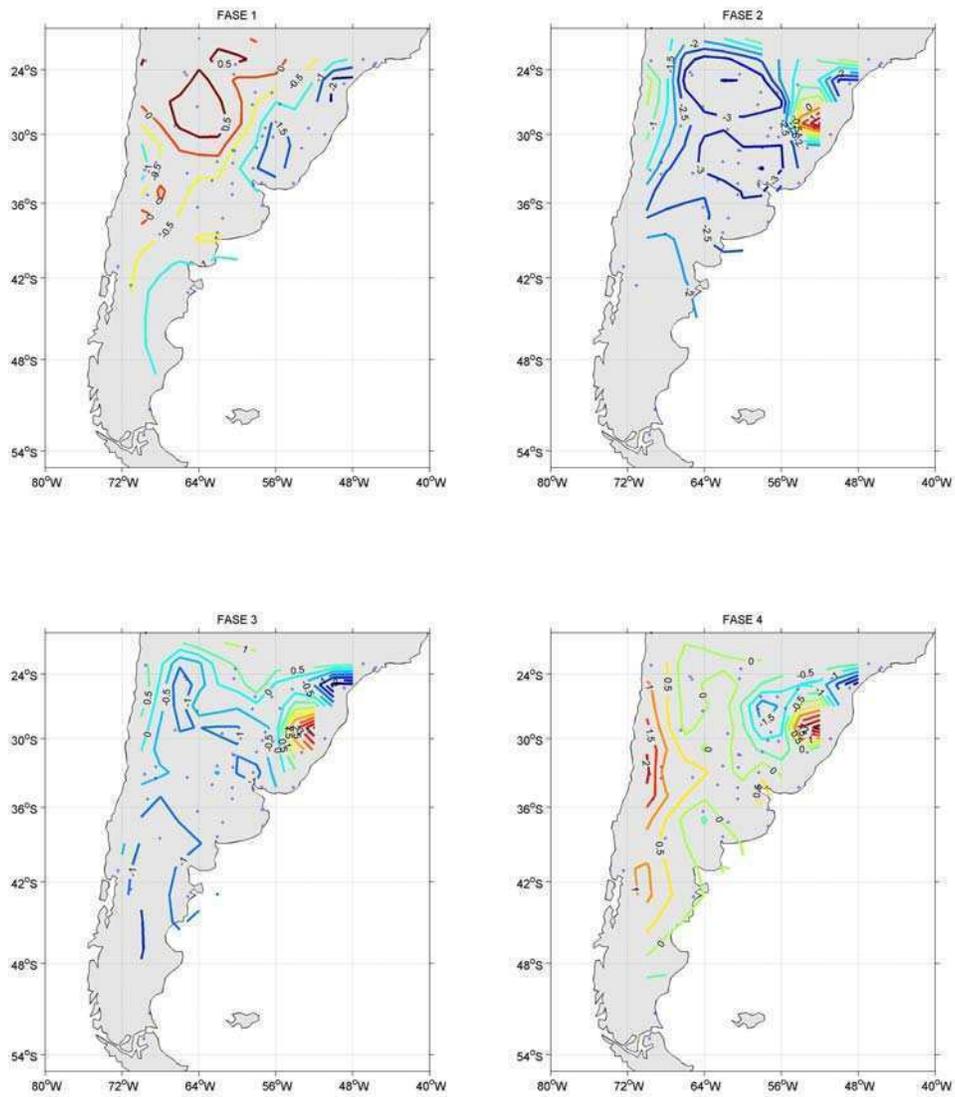


Figura 5.35a. Campos medios de anomalías de temperatura máxima de invierno (JJA) para las fases 1-4 de MJO con amplitud mayor al último tercil.

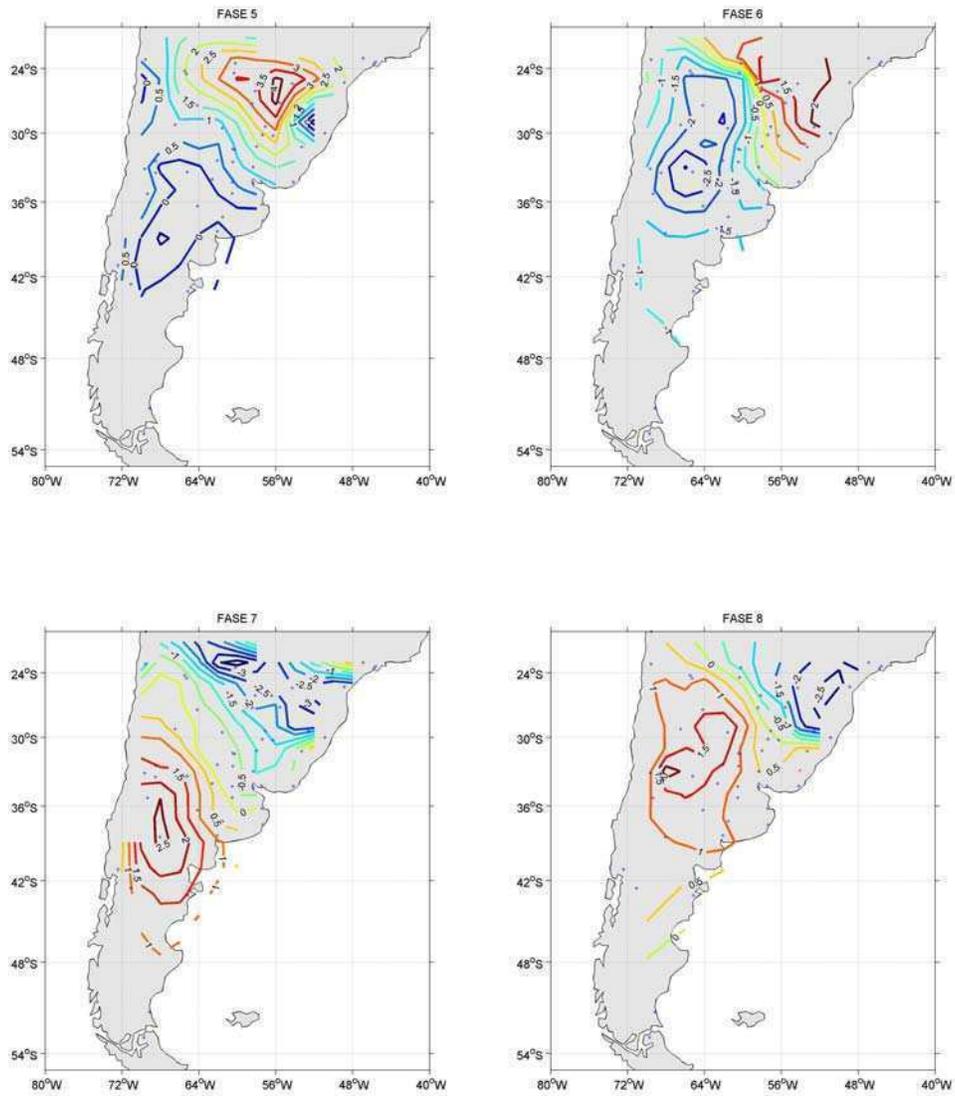


Figura 5.35b. Campos medios de anomalías de temperatura máxima de invierno (JJA) para las fases 5-8 de MJO con amplitud mayor al último tercil.

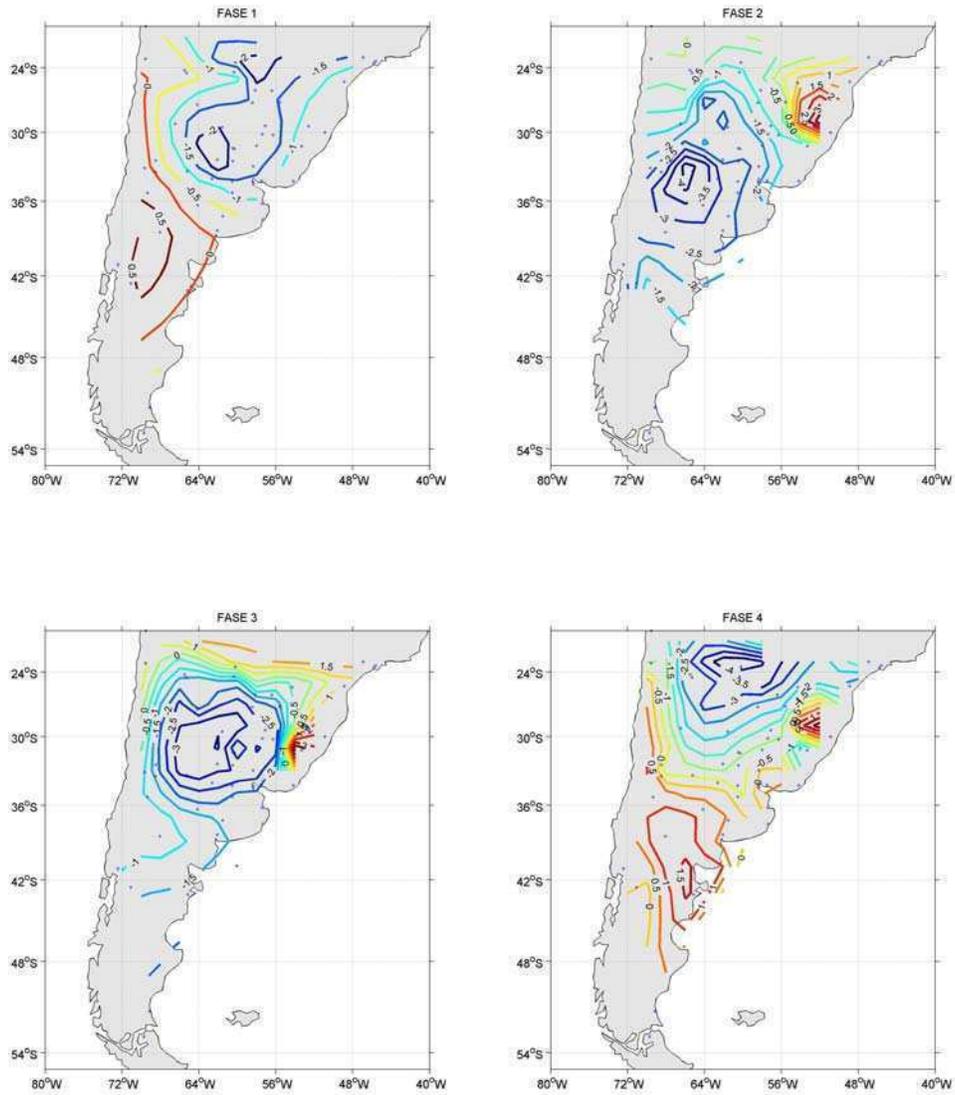


Figura 5.36a. Campos medios de anomalías de temperatura mínima de invierno (JJA) para las fases 1-4 de MJO con amplitud mayor al último tercil.

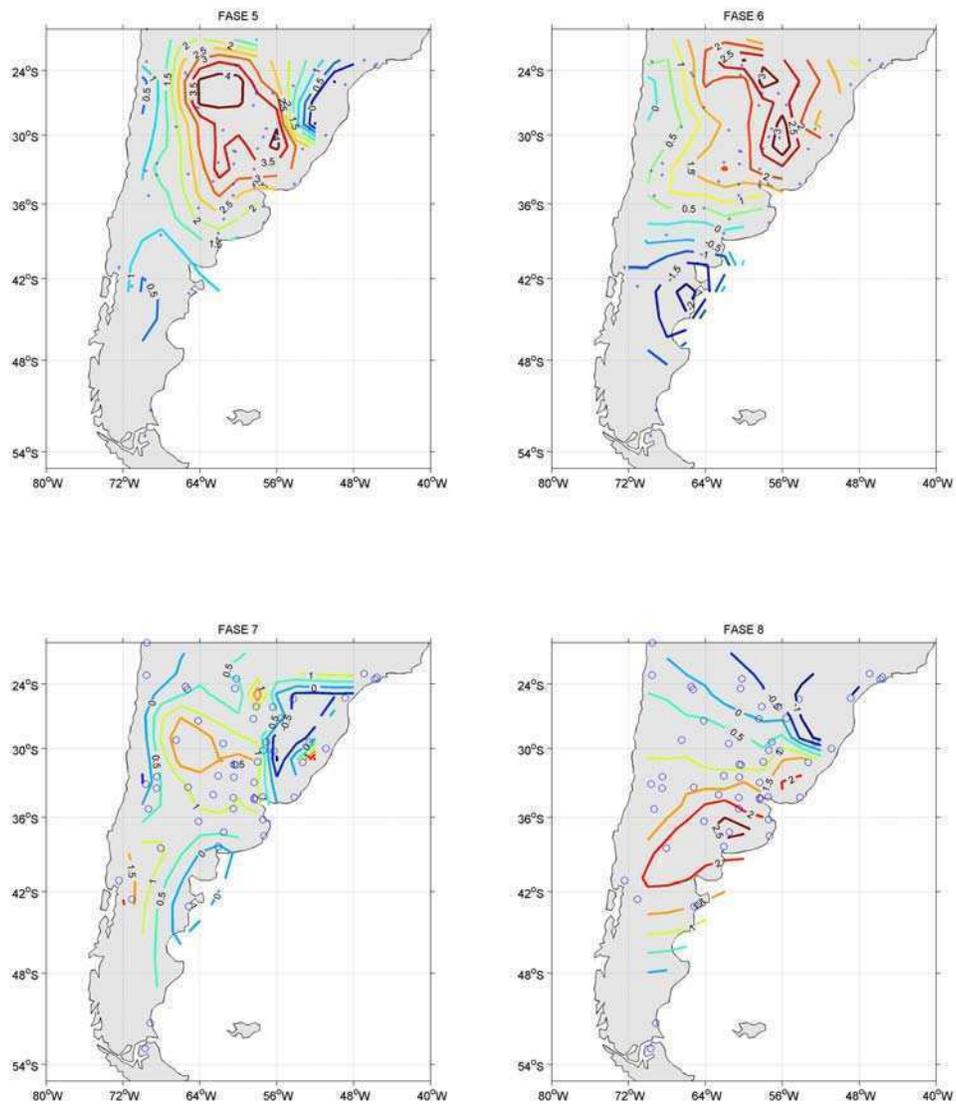


Figura 5.36b. Campos medios de anomalías de temperatura mínima de invierno (JJA) para las fases 5-8 de MJO con amplitud mayor al último tercil.

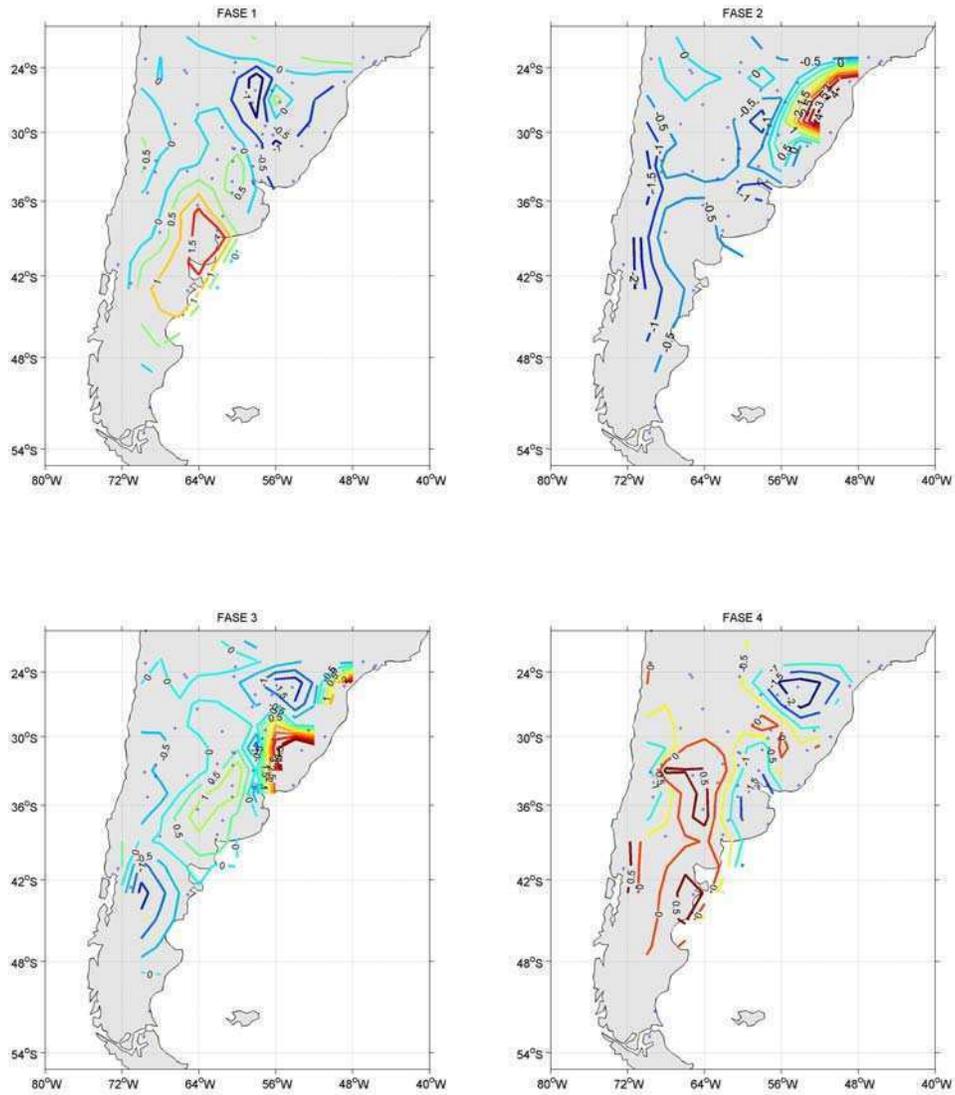


Figura 5.37a. Campos medios de anomalías de precipitación de invierno (JJA) para las fases 1-4 de MJO con amplitud mayor al último tercil.

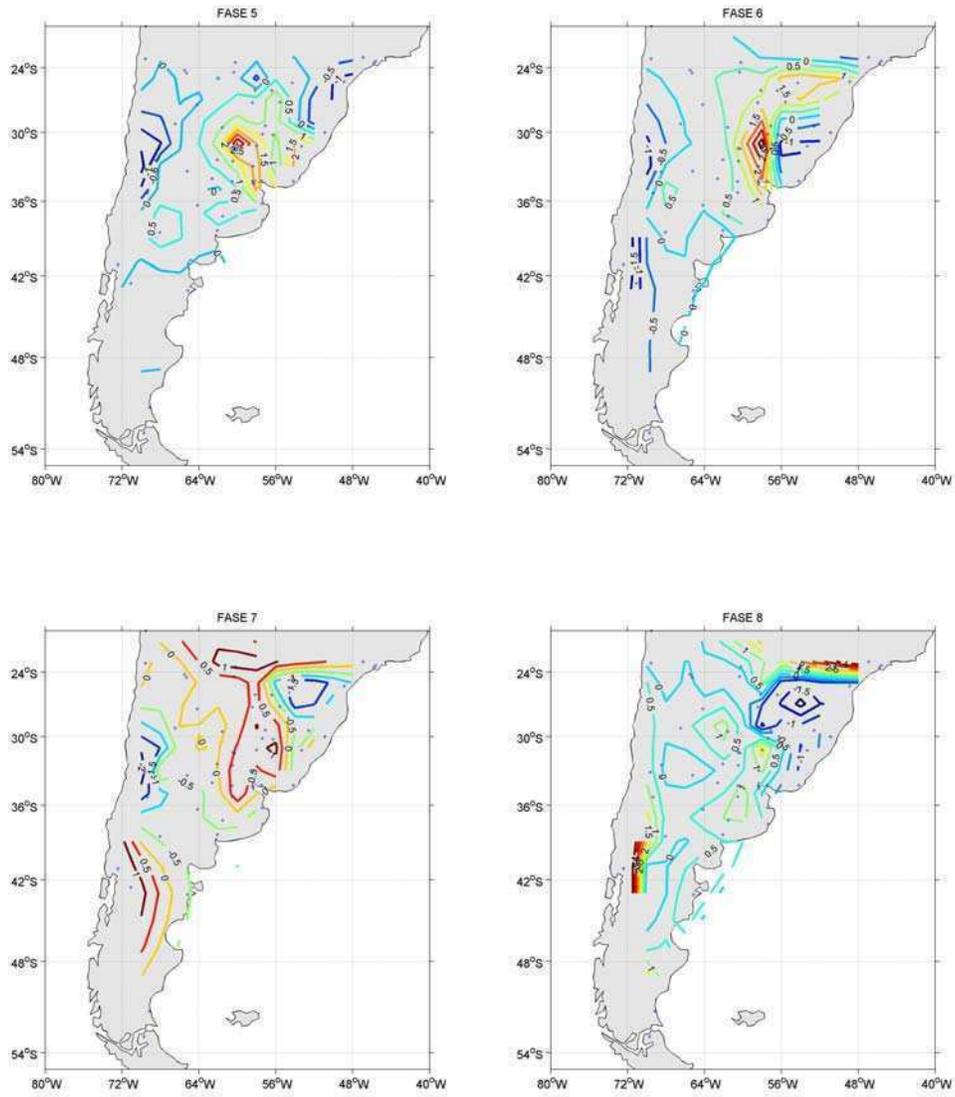


Figura 5.37b. Campos medios de anomalías de precipitación de invierno (JJA) para las fases 5-8 de MJO con amplitud mayor al último tercil.

5.4.2 Información mutua entre la temperatura y la oscilación de Madden-Julian

La Entropía conjunta y la información mutua son dos variables que miden el grado de información compartida entre variables. En el caso de la información mutua representa una medida de la reducción de la entropía de una variable debido al efecto de otra. En otras palabras, ésta representa la cantidad de información que dos o más variables tienen en común. Por esto, altos valores de información mutua indican una gran reducción en la incertidumbre, mientras que menores valores de MI representan una pequeña reducción de estas incertezas. Para dos variables aleatorias la información mutua es igual a cero.

Esta medida de correlación entre dos variables puede ser utilizada para examinar la relación entre la temperatura diaria y la MJO. Con este fin se analizó la información mutua entre la serie discreta producto de la clasificación bivariada de temperatura (ver capítulo 4) y las fases asociadas al índice bivariado que representa a la MJO. En la figura 5.38 se muestra la distribución espacial de la información mutua media entre las series diarias de temperatura discretizada mediante el análisis de cluster y la MJO. Aquí se observa un gradiente meridional de ésta variable cuyos máximos se tienen en las regiones tropicales. Por otro lado, se observa una máxima relación entre las dos variables analizadas en el sudeste de Brasil y parte del noreste argentino.

Este resultado concuerda con lo hallado en secciones anteriores y esta altamente relacionado con el fortalecimiento de la convección en los océanos Índico y Pacífico ecuatoriales. Respecto a este resultado Grimm y Silva Dias (1995) encontraron una considerable consistencia entre los patrones de circulación (más precisamente ondas de Rossby forzadas por la convección tropical) observados en escala de tiempo intraestacional (MJO) e interanual (ENSO). Así mismo, los autores encuentran una conexión de mecanismos dinámicos entre las oscilaciones de 30-60 días con la zona de convergencia del Atlántico Sur (SACZ).

Estos resultados indican que la información mutua entre la temperatura y la oscilación de Madden-Julian no es alta (aunque alcanza hasta 1 bit de información en el sudeste de Brasil), la distribución espacial de la señal es coherente con los procesos físicos asociados a teleconexiones con la oscilación intraestacional debida a la convección ecuatorial.

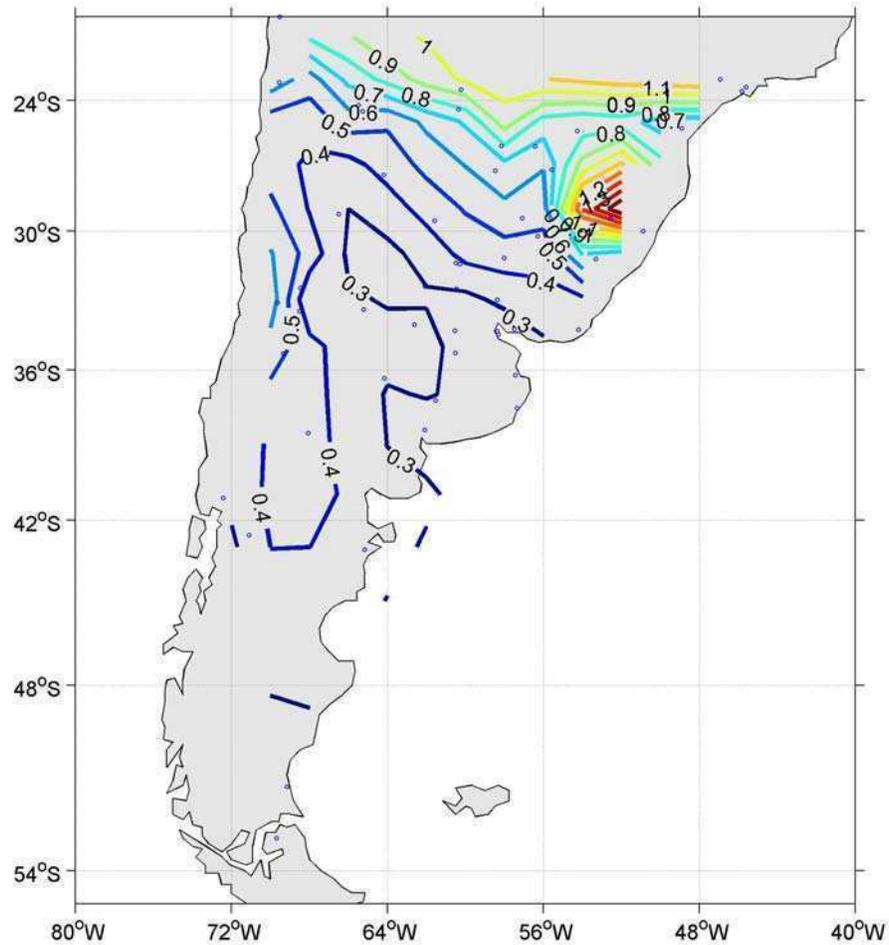


Figura 5.38. Información mutua media entre la clasificación bivariada de temperatura y el índice MJO.

Sin embargo, dado que los resultados de la figura 5.38 refieren a valores medios de información mutua y debido a que la amplitud de la MJO varía con el tiempo es de esperar períodos en que la temperatura y la MJO covarían en mayor/menor medida. Por esto en la próxima sección se muestran las variaciones locales de estas correlaciones y la inferencia sobre el diagnóstico conjunto.

5.4.3 Diagnóstico de la temperatura basada en análisis conjunto local

Bajo ciertas condiciones, principalmente en el caso de fenómenos de dinámica transitoria el análisis de la entropía media falla en detectar las correlaciones existentes entre variables.

Además, como se mostró en el capítulo anterior para el sistema climático las incertezas medias son mayores a 0.9 (cuando la entropía máxima es 1). Esto significa como propiedad principal que la predictabilidad media del sistema es baja (alrededor del 10%). Sin embargo, para aplicaciones prácticas, en general el valor medio de las diferentes propiedades que definen la predictabilidad del sistema no resulta de gran utilidad. Sin embargo, puede ser de gran importancia la predicción concreta basada en una secuencia finita de longitud N (entropía condicional y dinámica) o en la predicción dada por la relación entre dos variables que en determinados períodos de tiempo comparten información (entropía conjunta).

Dado que la entropía conjunta es una medida de la dependencia entre dos variables es posible detectar períodos en que esta medida decrezca localmente, lo que implica una coherencia entre procesos de las dos variables. Por esto, para analizar el comportamiento local que describe la relación entre la temperatura discretizada y la MJO se calculó la entropía conjunta y la información mutua sobre ventanas móviles de 30 días (figuras 5.39 a 5.42). Aquí se observa en general para toda la región, que existen periodos donde la información mutua duplica los valores medios y la entropía conjunta decrece desde valores de 0.8 hasta menos de 0.5.

Así mismo, en las localidades analizadas, la información mutua tiende a un comportamiento estacional definido. Esto refiere a máximos de información mutua en la época invernal y mínimos en durante el verano. Estos resultados concuerdan con lo hallado en secciones anteriores, donde la mayor señal intraestacional sobre la temperatura se observa durante el invierno.

Estos resultados implican que para estos períodos es posible efectuar un diagnóstico del comportamiento de la temperatura en la región a partir del análisis de la variabilidad de la MJO. Por otro lado, dado que en la actualidad es posible pronosticar la MJO con una buena performance hasta 15-17 días (Seo, et al 2009), es posible utilizar esta información para inferir sobre el pronóstico de la temperatura en la región en esa escala temporal.

Finalmente, se destaca que es necesario explorar sobre las condiciones locales en que la MJO puede resultar como en un buen predictor de la temperatura en Sudamérica a través del análisis de la entropía conjunta y condicional de los distintos procesos conjuntos que conllevan a eventos térmicos extremos en la región.

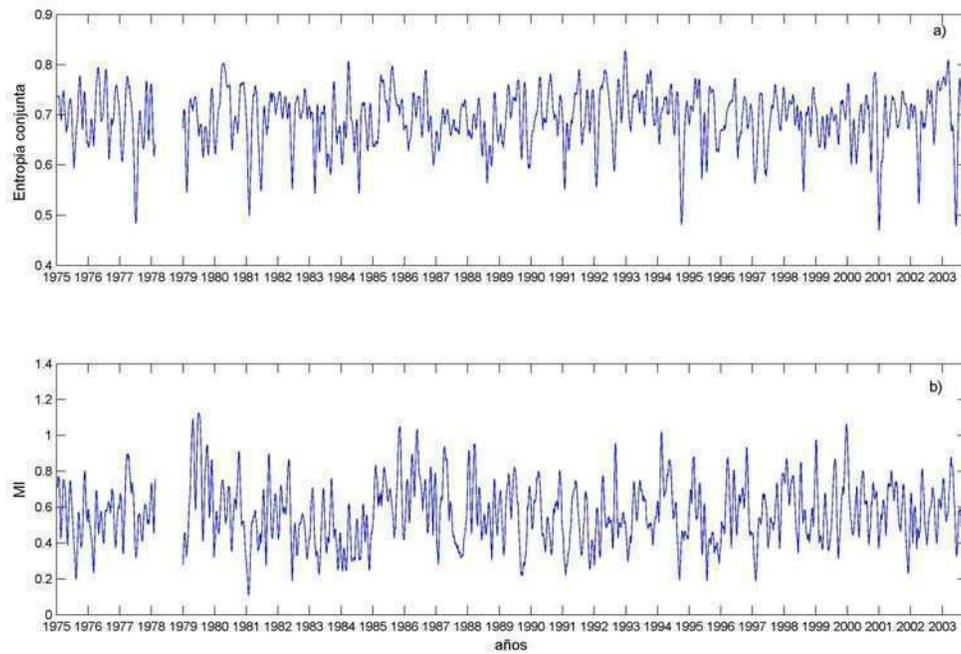


Figura 5.39. Entropía conjunta (a) e información mutua (b) entre la estructura térmica en Campinas y la MJO.

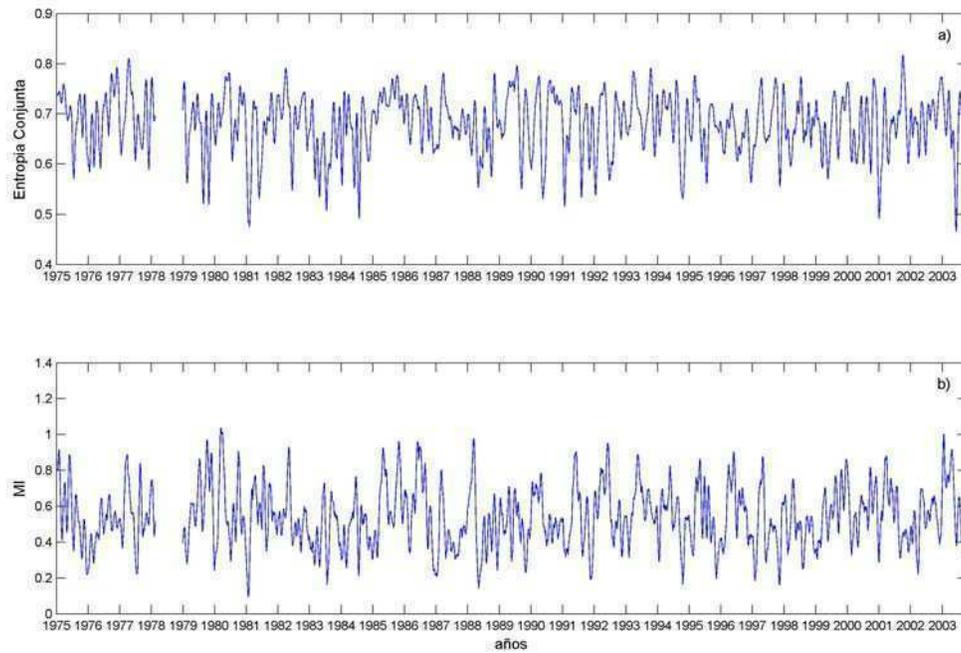


Figura 5.40. Entropía conjunta (a) e información mutua (b) entre la estructura térmica en Corrientes y la MJO.

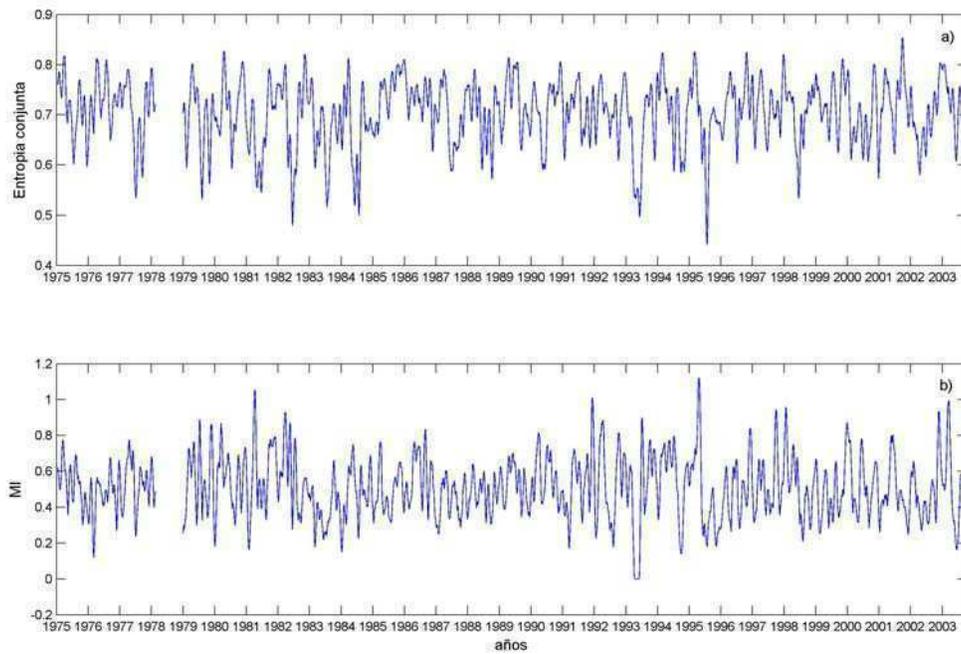


Figura 5.41. Entropía conjunta (a) e información mutua (b) entre la estructura térmica en Pergamino y la MJO.

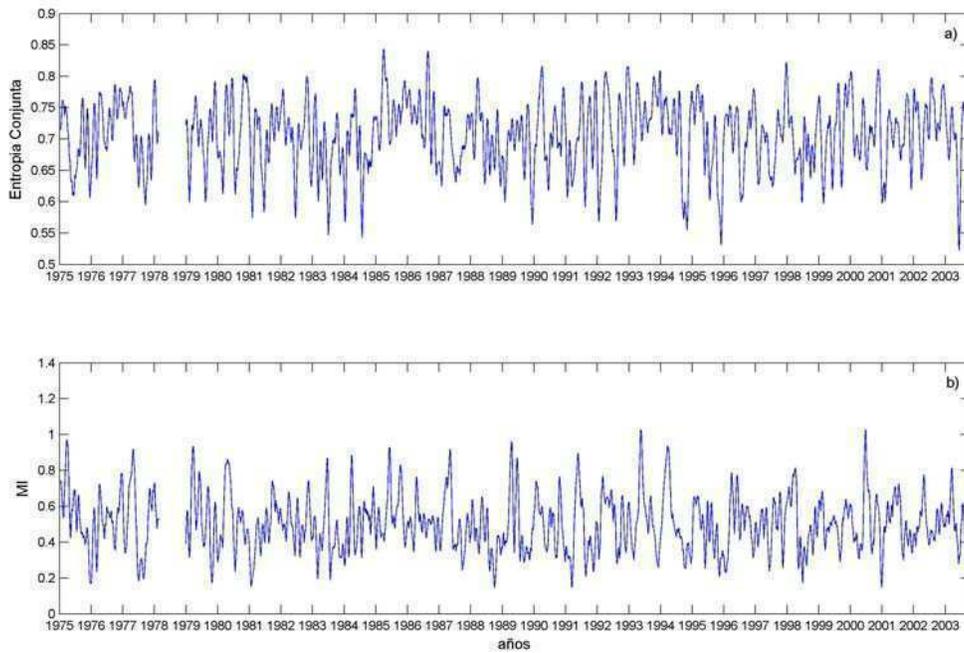


Figura 5.42. Entropía conjunta (a) e información mutua (b) entre la estructura térmica en Río Gallegos y la MJO.

CONCLUSIONES

El objetivo principal de este trabajo de tesis es avanzar en el conocimiento de la variabilidad climáticas de baja frecuencia dentro de la escala intraestacional en series de temperatura diaria en Sudamérica. Para esto es necesario elaborar un diagnóstico objetivo para este tipo de variabilidad para poder inferir sobre el impacto de éstas en los sistemas culturales.

Para lograr un diagnóstico objetivo es necesario obtener un filtro o función de transferencia que introduzca la menor cantidad de ruido debido a que un análisis en escala diaria puede ser oscurecido por su elección. Para esto, en el capítulo 2 se analiza la robustez y estabilidad de diferentes métodos para estimar la onda anual. Aquí se muestra la presencia de asimetrías en la onda anual de temperatura que en algunos casos son producto de interacciones no lineales entre la onda anual y las perturbaciones. Además se muestra que el cálculo de la onda anual a partir de la mediana produce una estimación más robusta para períodos de información menores a 50 años. Sin embargo, para períodos mayores de información no se observan diferencias entre los distintos estimadores.

Por otro lado, existe una dependencia entre el tiempo de independencia (T_0) y el período analizado, es decir existe una variación interanual de T_0 que puede variar en la región entre 3 y 7 días. Este efecto posiblemente está asociado a variaciones entre períodos húmedo/secos. Además se observa un mayor T_0 si se considera el término no lineal de las anomalías, es decir el análisis de ésta componente conduce a estimar efectos más persistentes que se ven afectados por la pendiente de la onda anual.

En general los procesos asociados a una relación no lineal con la onda anual evidencian una mayor persistencia de las anomalías cálidas. Esto está asociado a procesos advectivos lentos donde las masas de aire cálido permanecen durante varios días, efecto que se evidencia mejor sobre la temperatura mínima.

Para el análisis de la persistencia se analizó la marcha anual de los primeros tres coeficientes de autocorrelación donde se observa en la temperatura mínima una mayor tasa de variación de la persistencia y el tiempo de independencia durante el invierno y la primavera, al contrario de lo que ocurre con la temperatura máxima donde el mayor cambio se observa en otoño. De esto, se desprende que para la temperatura máxima, variable altamente dependiente de la nubosidad, y para la temperatura mínima mayormente influenciada por las irrupciones frías/cálidas, los cambios observados están reflejando en

cierto modo los procesos que conducen al comienzo o finalización de la temporada fría y seca. Por este motivo si se desea representar la persistencia en estas variables es necesaria una mayor descripción de los parámetros que definen la serie durante las estaciones de transición, principalmente el otoño en la temperatura máxima y en primavera para la temperatura mínima. Aquí, los primeros coeficientes de autocorrelación varían más rápidamente. Así mismo, dada las variaciones estacionales del tiempo de independencia, al considerar este resultado es posible optimizar el número de observaciones independientes de las series temporales.

Con estos elementos es posible desprender una aplicación directa del análisis. Por esto, en concordancia con lo propuesto por Minetti y Vargas (1997) es posible proponer dos modelos de pronóstico objetivo basados en las interacciones lineales asociados a la persistencia y otro que permita utilizar la información de las interacciones no lineales que se manifiestan en forma de precursores (asociaciones significativas del día i con el día $i+11$ hasta el día $i+180$).

Si consideramos un análisis espacial de la persistencia, en toda la región al norte del paralelo $S36^\circ$ se observa la mayor dependencia para los meses de otoño y comienzo del invierno, siendo estos valores de dependencia entre 4 y 7 días. Al sur de este dominio y en la porción continental se observan que los días más persistentes se dan en primavera. Esto no ocurre en la costa atlántica de la Patagonia donde los días con mayor cantidad de memorias significativas se deben buscar entre fines de otoño y comienzo del invierno. Para los precursores se tiene una mayor tendencia a la presencia de memoria distantes en las series de temperatura entre invierno y primavera en el norte y centro de Argentina y sur de Brasil. Esto se manifiesta en esta región mediante la cantidad de entre 15 y 20 asociaciones distantes significativas por día del año. Así mismo, la Patagonia muestra un comportamiento diferenciado donde la mayor preferencia a la ocurrencia de precursores es durante el otoño.

Se observan variaciones de baja frecuencia sobre la persistencia en la región de entre 16 y 22 años. Estos cambios evidencian probablemente la variación en la frecuencia de distintos tipos de circulación que tienen un impacto directo en la estructura térmica regional. Así mismo, variaciones de este tipo pueden tener serios impactos socio-económicos ya que estos afectarían directamente la frecuencia y duración de los eventos extremos. Por esto el

seguimiento o monitoreo de los cambios de estado en escala intraanual de las variables que definen tanto a la persistencia como a la antipersistencia se vuelve una herramienta necesaria a la hora de decidir sobre la validez y comprensión de las características generales del modelo de pronóstico objetivo a utilizar.

El análisis conjunto de un algoritmo de cluster con el análisis de memoria del sistema a través de la entropía condicional y las distribuciones de cambio de estado permite realizar una mejor descripción de estructuras climatológicas complejas

A través de un análisis espacial de la entropía se encontró que existe un gradiente meridional en todo el dominio, encontrándose el máximo en la porción sur de Sudamérica. Además, tomando en cuenta la baja predictabilidad del sistema, pequeños cambios en estas propiedades implican una variabilidad significativa. En este estudio, el gradiente muestra que la predictabilidad en la región norte es el doble respecto con lo que ocurre en latitudes medias de Sudamérica.

Los cambios temporales de la entropía condicional se evidencian en forma de cuasi-ciclos. Si se analizan la variabilidad de baja frecuencia en esta variable a través de la estimación espectral, se infiere que el período dominante es aproximadamente de 18 años.

Un comportamiento temporal opuesto se observa entre la entropía condicional asociada al conjunto de días fríos y cálidos. Es decir, ésta variable disminuye en el caso de que aumente la persistencia ya que la entropía condicional aumenta con una mayor presencia de transiciones entre los estados cálido y frío y su inversa.

Teniendo en cuenta los cambios observados en la persistencia y la entropía condicional sobre todo en los grupos que representan a los días fríos y cálidos, estos pueden sugerir variaciones en los modelos de predicción para el pronóstico objetivo que utilizan el conocimiento de series temporales.

Por otro lado se infiere que los cambios en la distribución de los patrones de circulación podrían afectar directamente el pronóstico objetivo. Finalmente, el estudio de la variabilidad a largo plazo de la entropía podría sugerir algunas evidencias de los cambios climáticos.

La identificación en el tiempo de las estructuras espectrales que son producto de la presencia de fenómenos físicos transitorios permite detectar períodos en que la predictabilidad del sistema aumenta y por consiguiente obtener una mejora en el momento de la elaboración de un pronóstico objetivo.

Para la temperatura máxima y mínima se observa que los meses invernales son los que evidencian la mayor señal de variabilidad intraestacional. Para la temperatura máxima la ocurrencia de esta señal intraestacional es un poco más compleja, donde en algunas estaciones (Campinas, Tucumán, Pergamino, Pilar y Santa Rosa) esta característica tiende a tener una distribución bimodal. Aquí, los máximos tienden a ocurrir al inicio y final del invierno. También, los máximos se asocian al inicio y final de una marcada estación seca.

Así mismo la presencia de ciclos de entre 30 y 60 días muestran en general una persistencia de entre 30 a 200 días. Es decir que las transiciones entre eventos cálidos y fríos se suceden con el período citado durante un mes y puede persistir hasta por tres estaciones, generalmente centrada en el invierno.

En cuanto a la frecuencia interanual en que se evidencian este tipo de oscilaciones, se observa que este fenómeno tiene una probabilidad de ocurrencia de entre 30 y 50%. Así mismo, se observa que existe una mayor tendencia a aparecer en intervalos de 1-2 años, menos frecuentemente en intervalos de 4-8 años y excepcionalmente cada 12 años.

En cuanto a la distribución espacial de la señal intraestacional se tiene un gradiente meridional con pocas variaciones espaciales con amplitudes de las anomalías de temperatura entre 2 y 3 °C en casi toda la región. La región que presenta mayores diferencias, es la noreste de Argentina y principalmente es el sur de Brasil, donde se observan amplitudes máximas cercanas a 5 °C. Aquí se destaca el comportamiento diferenciado que muestra el Noreste de Argentina y el sur de Brasil, región donde el impacto del ENOS es mayor (El Niño-Oscilación del Sur), principalmente sobre la precipitación.

A partir del análisis de componentes principales se tiene un modo principal que se caracteriza por el aumento de la señal intraestacional durante el invierno tanto para la temperatura máxima como la mínima. En general para las dos variables se observa que el inicio de esta señal está asociado a una irrupción cálida (fría) de aire intensa seguida treinta

días después por una irrupción fría (cálida) de gran intensidad. Seguido a esto, durante el mes de julio se observa una irrupción calida (fría) para finalmente aproximadamente 30 días después registrarse otra irrupción fría (cálida) intensa. Antes y después de este período la señal intraestacional tiende a ser incoherente y a tener amplitudes despreciables.

Respecto a la asociación entre la temperatura y la MJO se observa que las señales de la temperatura asociada con la MJO son espacialmente coherentes. Para la temperatura mínima se observan anomalías cálidas sobre toda la región norte del dominio para las fases 5 y 6 de la MJO. Por otro lado para las fases 2 y 3 se observa el comportamiento inverso, con anomalías frías en casi toda la región, excepto en el sudeste de Brasil. Cabe destacar que las anomalías observadas, tanto en las fases de calentamiento como de enfriamiento, son estadísticamente significativas y exceden en casi todas las regiones valores de 1°C , hasta alcanzar incluso valores medios de 4°C .

También se observa un comportamiento coherente entre lo que se muestra para la temperatura máxima y la precipitación, principalmente en el noreste del dominio. En las fases 3 y 5 se observan anomalías positivas de precipitación en el centro este de la región, mientras que se tienen anomalías negativas en la Patagonia y Andes centrales. Las fases 1, 4 y 7 se caracterizan por el comportamiento opuesto con déficit de precipitación en el sudeste de Brasil y noreste de Argentina. Además se destaca para la fase 1 excesos en la Patagonia y cordillera central.

Dado que la entropía conjunta es una medida de la dependencia entre dos variables es posible detectar períodos en que esta medida decrezca localmente, lo que implica una coherencia entre procesos de las dos variables. Por esto, para analizar el comportamiento local que describe la relación entre la temperatura discretizada y la MJO se calculó la entropía conjunta y la información mutua sobre ventanas móviles de 30 días. Aquí se observa en general para toda la región, que existen periodos donde la información mutua duplica los valores medios y la entropía conjunta decrece desde valores de 0.8 hasta menos de 0.5.

Así mismo, en las localidades analizadas, la información mutua tiende a un comportamiento estacional definido. Esto refiere a máximos de información mutua en la época invernal y mínimos en durante el verano. Estos resultados concuerdan con lo hallado en secciones anteriores de la tesis, donde la mayor señal intraestacional sobre la

temperatura se observa durante el invierno. Estos resultados implican que para estos períodos es posible efectuar un diagnóstico del comportamiento de la temperatura en la región a partir del análisis de la variabilidad de la MJO.

Finalmente, se destaca que es necesario explorar sobre las condiciones locales en que la MJO puede resultar un buen predictor de la temperatura en Sudamérica a través del análisis de la entropía conjunta y condicional de los distintos procesos conjuntos que conllevan a eventos térmicos extremos en la región.

REFERENCIAS

Abbot, P., 1984: Guidelines on the quality control of surface climatological data. World Climate Program. WMO / TD -Nº 111, pág 1-6

Baliunas, S., P. Frick, D. Sokoloff, W. Soon, 1997: Time Scales and Trends in the Central England Temperature Data (1659-1990): A Wavelet Analysis. - *Geophys. Res. Lett.* 24, 1351-1354.

Balling, R. C., Jr., and S. S. Roy, 2004: A spatial entropy analysis of temperature trends in the United States, *Geophys. Res. Lett.*, 31, L09201, doi:10.1029/2004GL019630.

Barnett, T. P., and R. Preisendorfer, 1987: Origins and levels of monthly and seasonal forecast skill for United States surface air temperatures determined by canonical correlation analysis. *Mon. Wea. Rev.*, **115**, 1825–1850.

Barros V, Camilloni I, 1994: Urban biased trends in Buenos Aires mean temperature. *Clim Res* 4:33–45

Barros VR, Doyle ME, Camilloni IA, 2008: Precipitation trends in southeastern South America: relationship with ENSO phases and with low-level circulation. *Theoretical and Applied Climatology* 93(1-2): 19

Barrucand, M. G. y Rusticucci, M. M., 2001: Climatología de temperaturas extremas en la Argentina. *Variabilidad temporal y regional. Meteorologica*, Vol 26, 1 y 2, 85-102.

Báth M., 1974: Spectral analysis in geophysics. *Developments in solid earth geophysics*. Elsevier, Amsterdam, 1974, 563 pp.

Bayley, G. F and J. M. Hammersley, 1946: The effective number of independent observations in an autocorrelated time series. *J. Roy. Soc. Ser. 1B*, 8, 184-197

Blackman, R. B., Tuckey J. W., 1958: The Measurement of Power Spectra (Dover. Mineola, NY).

Borisova, L. G., and L. M. Rudiceva, 1968: The use of special features of natural synoptic seasons in making monthly weather forecasts. *Trudy*, **12**, 12–18..

Box, G.E.P; Jenkins, G.M., 1970: Time Series Analysis: Forecasting and Control, San Fransisco. Holden-Day.

Brinkmann W. A., 1983: Variability of temperature in Wisconsin. *Mon. Wea. Rev.* 111, 172-179.

Brooks C. E. P., and N. Carruthers, 1953: *Handbook of Statistical Methods in Meteorology*. MO 538. Her Majesty's Stationery Office, 412 pp.

Camilloni I, Barros V, 1997: On the urban heat island effect dependence on temperature trends. *Climate Change* 37:665–681

Campetella, C., Rusticucci, M., 1998: Synoptic analysis of an extreme heat wave over Argentina in March 1980, *Meteorological Applications*, 1998, Vol 5, N.3, 217-226.

Cerne, B. y M. Rusticucci, 1997: Estudio de la situación sinóptica asociada con la ola de frío de febrero de 1996, *Meteorológica*, Vol 22, No.2, 5-18

Cerne, B., 1998. La variabilidad intraestacional de la temperatura y su importancia en el desarrollo de olas de calor en el centro de argentina. Ph D. Thesis. FCEyN-UBA.

Compagnucci E.R., W.M. Vargas, 1983: Análisis espectral de las series de precipitación estival. *Meteorológica* 34: 213-224.

Chandler, T. J., 1965: The climate of London. Hutchinson & Co., London.

Chatfield, C., 1989: The analysis of time series: An introduction ;, 4th ed. (Chapman & Hall, London, U.K.)

Daubechies, I., 1990: The wavelet transform time-frequency localization and signal analysis. *IEEE Trans. Inform. Theory*, **36**, 961–1004.

Daubechies, I, 1992: *Ten Lectures on Wavelets*. Society for Industrial and Applied Mathematics, 357 pp.

DelSole, T., and M. K. Tippett, 2007: Predictability: Recent insights from information theory, *Rev. Geophys.*, **45**, RG4002, doi:10.1029/2006RG000202.

Deque, M., 1988: 10-day predictability of the northern hemisphere winter 500-mb height by the ECMWF operational model. *Tellus*, **40A**, 26-36.

Ding C. and Xiaofeng He, 2004: "K-means Clustering via Principal Component Analysis". *Proc. of Int'l Conf. Machine Learning (ICML 2004)*, 225-232.

Doblas-Reyes F.J., M. Déqué, F. Valero and D. B. Stephenson, 1998: North-Atlantic wintertime intraseasonal variability and its sensitivity to GCM horizontal resolution. *Tellus*, **50A**, 573-595.

Ebeling, W., and G. Nicolis, 1992: Word frequency and entropy of symbolic sequences: A dynamical perspective, *Chaos Solitons Fractals*, **2**, 635– 650.

Ebeling, W., 1997: Prediction and entropy of sequences with LRO. *Physica D* **109** 42-50.

Farge, M., 1992: Wavelet transforms and their applications to turbulence. *Annu. Rev. Fluid Mech.*, **24**, 395–457.

Ebeling, W., 2002: Entropies and predictability of nonlinear processes and time series, in Computational Science—ICCS 2002. 2nd International Conference, Amsterdam, the Netherlands, April 21–24, 2002 Proceedings Part 3, Lect. Notes Comput. Sci., vol. 2331, edited by P. M. A. Sloot et al., pp. 1209–1217, Springer, London.

Feistel, R., Ebeling, W., 1989: Evolution of Complex Systems, Kluwer Academic Publ., Dordrecht.

Foufoula-Georgiou, E., and P. Kumar, Eds., 1995: *Wavelets in Geophysics*. Academic Press, 373 pp.

Gabriel K. R., J. Neumann, 1962: A Markov chain model for daily rainfall occurrence at Tel Aviv., Quarterly Journal of the Royal Meteorological Society. 88, 375. 90-95.

Gandin, L. S., 1970: The Planning of Meteorological Station Networks. Technical Note N° 111. World Meteorological Organization. Geneva- Switzerland.

Ghil, M., and K. Mo, 1991a: Intraseasonal Oscillations in the Global Atmosphere. Part I: Northern Hemisphere and Tropics. J. Atmos. Sci., 48, 752–779

Ghil, M., and K. Mo, 1991b: Intraseasonal Oscillations in the Global Atmosphere. Part II: Southern Hemisphere. J. Atmos. Sci., 48, 780–790

Grimm, A. M., and P. L. Silva Dias, 1995: Analysis of tropical-extratropical interactions with influence functions of a barotropic model. *Journal of the Atmospheric Sciences*, **52**, 3538-3555.

Gonzalez, P; Vera, C; Liebmann, B; Kiladis, G., 2008: Intraseasonal variability in subtropical South America as depicted by precipitation data.. *Climate Dynamics*. vol. 30 p.727-744

Hartigan, J., 1975: *Clustering Algorithms*. Wiley, New York, NY.

Hartigan, J. A. and Wong, M. A. (1979). A K-means clustering algorithm. *Applied Statistics* **28**, 100–108.

Harvey, A., 1990: Forecasting, structural time series models, and the Kalman filter. Published by Cambridge University Press.

Haylock, M.R., T.C. Peterson, L.M. Alves, T. Ambrizzi, Y.M.T. Anunciação, J. Baez, V.R. Barros, M.A. Berlato, M. Bidegain, G. Coronel, V. Corradi, V.J. Garcia, A.M. Grimm, D. Karoly, J.A. Marengo, M.B. Marino, D.F. Moncunill, D. Nechet, J. Quintana, E. Rebello, M. Rusticucci, J.L. Santos, I. Trebejo, and L.A. Vincent, 2006: Trends in Total and Extreme South American Rainfall in 1960–2000 and Links with Sea Surface Temperature. *J. Climate*, 19, 1490–1512.

Higgins, R.W., and K.C. Mo, 1997: Persistent North Pacific Circulation Anomalies and the Tropical Intraseasonal Oscillation. *J. Climate*, 10, 223–244.

Hoel, P., 1976: Introduction to Mathematical Statistics. -Wiley John and Sons, Inc. New York, London.

Hoffmann, J. A., 1990: De las variaciones de de la Temperatura del Aire en la Argentina y Estaciones de la Zona Subantártica Adyacente, desde 1903 hasta 1989 inclusive. *Meteorológica*. Vol. 17, N° 1 y 2. 1990

Hoffmann, J., Nuñez, S. y Vargas W, 1997: Temperature, humidity and precipitation variations in Argentina and the adjacent sub-Antarctic region during the present century. *Meteor. Z.*, 6, 3-11

Jenkins, G.M., and Watts, D., 1968: Spectral Analysis and its applications. Published by Holden-Day.

Jones, P. D., Kelly, P. M., Goodess, C.M., and Karl, T. R., 1989: The effect of Urban Warming on the Northern Hemisphere Temperature Average. *J. of Climate* 2, 285-290.

Jones, C. 2000: Occurrence of extreme precipitation events in California and relationships with the Madden-Julian Oscillation. - *J. Climate* **13**, 3576– 3587.

Kaiser, G., 1994: *A Friendly Guide to Wavelets*. Birkhäuser, 300 pp.

Kalnay, E., M. Kanamitsu, R. Kistler, W. Collins, D. Deaven, L. Gandin, M. Iredell, S. Saha, G. White, J. Woollen, Y. Zhu, A. Leetmaa, R. Reynolds, M. Chelliah, W. Ebisuzaki, W. Higgins, J. Janowiak, K. Mo, C. Ropelewski, J. Wang, R. Jenne, D. Joseph, 1996: The NCEP/NCAR 40-Year Reanalysis Project. - *Bull. Amer. Meteor. Soc.* **77**, 437–471.

Karl, T. R., Díaz H. F. y Kukla, G., 1988: Urbanization: its detection and effect in the United States climate record. *J. of Climate* 1, 1099-1123.

Kaufman, L. and Rousseeuw, P.J., 1990: *Finding Groups in Data: An Introduction to Cluster Analysis*. Wiley, New York.

Koepfen, W., 1948: *Climatología*. Fondo de Cultura Económica, México. 477 pp.

Lamb, H. H., 1972: *Climate: Present, Past and Future*. Methuen and Co., 613 pp..

Lau, K.-M. and F. C. Chang, 1992: Tropical intraseasonal characteristics of large-scale and extended range forecasts in the NMC operation model. *J. Climate* 5, 1365–1378.

Leith C. E., 1973: The standard error of time-average estimates of climatic means. *J App Meteorol* 12: 1066-1069.

Leith, C. E., 1978: Objective methods for weather prediction. *Annual Review of Fluid Mechanics*,10, 107–128.

Leung, L.Y., and G.R. North, 1990: Information Theory and Climate Prediction. *J. Climate*, **3**, 5–14.

Liebmann, B., C.S. Vera, L.M.V. Carvalho, I.A. Camilloni, M.P. Hoerling, D. Allured, V.R. Barros, J. Báez, and M. Bidegain, 2004: An Observed Trend in Central South American Precipitation. *J. Climate*, **17**, 4357–4367.

Lorenz, E. N., 1963: Deterministic nonperiodic flow. *J. Atmos. Sci.*, **20**, 130–141.

Lorenz, E. N., 1965: A study of the predictability of a 28-variable atmospheric model. *Tellus*, **17**, 321–333.

Lorenz, E. N., 1968: Climate determinism. *Meteorol. Monogr.* **8**: 1–3

Lorenz, E. N., 1969: The predictability of a flow which possesses many scales of motion. *Tellus*, **21**, 289–307.

Lorenz, E. N., 1975: Climatic predictability. *The Physical Basis of Climate and Climate Modelling*, B. Bolin et al., Eds., GARP Publication Series, Vol. 16, World Meteorological Organization, 132–136.

Lorenz, E. N., 1976: Nondeterministic theories of climate change. *Quat. Res.* **6**: 495–506.

Lozowski, E. P., Charlton, R. B., Nguyen, C. D. & Wilson, J. D., 1989: The use of cumulative monthly mean temperature anomalies in the analysis of local interannual climate variability. *J. of Climate* **2**, 1059–1068.

MacQueen, J., 1967: Some methods for classification and analysis of multivariate observations. In Le Cam, L. M. and Neyman, J., editors, *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability. Volume I: Statistics*, pages 281–297. University of California Press, Berkeley and Los Angeles, CA.

Madden R., P. Julian, 1971: Detection of a 40-50 day oscillation in the zonal wind in the tropical Pacific. - *J. Atmos. Sci.* **28**, 702-708.

Madden R., P. Julian, 1972: Description of global-scale circulation cells in the tropics with a 40-50 day period. - *J. Atmos. Sci.* **29**, 1109-1123.

Madden, R. A. 1976: Estimates of the natural variability of time-averaged sea level pressure. *Mon. Wea. Rev.* 104, 942-952

Madden, R.A., and D.J. Shea, 1978: Estimates of the Natural Variability of Time-Averaged Temperatures over the United States. *Mon. Wea. Rev.*, **106**, 1695–1703.

Madden R. and P. Julian, 1994: Observations of the 40-50 day tropical oscillation: A review. - *Mon. Wea. Rev.* 112, 814-837.

Makridakis, S. and Wheelwright, S.C., 1989: *Forecasting Methods for Management* (5th edition). Chichester: Wiley.

Makridakis, S.G., S. Wheelwright and V. McGee, 1998: *Forecasting: Methods and Applications* (3d ed.), Wiley, New York.

Matthews A. J., G. N. Kiladis, 1999: The Tropical–Extratropical Interaction between High-Frequency Transients and the Madden–Julian Oscillation. -*Mon. Wea. Rev.* **127** 661-667.

Matthews A. J., M. P. Meredith, 2004: Variability of Antarctic circumpolar transport and the Southern Annular Mode associated with the Madden-Julian Oscillation. - *Geophysical Research Letters*, VOL. **31**, doi:10.1029/2004GL021666.

Minetti J.L., 1989: Comportamiento temporal de las precipitaciones de primavera y verano de San Miguel de Tucumán. *RIAT* 66(1): 83-95, EEAOC, San Miguel de Tucumán.

Minetti J.L., M.C. Carletto, 1990: Estructura espectral de las precipitaciones en ambos lados de la Cordillera de los Andes en Chile y Argentina. *Rev. De Geofísica* 46: 65-74.

Minetti, J.L., 1991: Estudio de las singularidades climáticas en series de temperaturas del Noroeste Argentino. - Ph D. Thesis. FCEyN-UBA. 117 pp.

Minetti, L. y Vargas, W., 1997a: Inhomogeneidades en series de temperatura del Noroeste Argentino para el periodo instrumental. *Meteorológica*. Vol. 22, N° 1.

Minetti, J. L. y Vargas, W. M., 1997b: Interaction Processes between the Annual Wave and the Disturbances in Series of Daily Temperature. *Int. J. of Climatol.* 10, 299-305.

Minetti J., Vargas W.M., 1998: Trend and Jumps in the annual precipitation in South America, south of the 15°S. *Atmósfera* 11:205–223 México.

Minetti, J.L., W.M.Vargas, A.G.Poble, L.R.Acuña And G.Casagrande, 2004: Non-Linear trends and low frequency oscillation in annual precipitation over Argentina and Chile, 1931-1999. *Atmósfera* 16, 119-135.

Minetti, J.L. y W.M. Vargas, 2005: La circulación regional en el Noroeste Argentino y condiciones del tiempo asociadas. En *el Clima del Noroeste Argentino*, Ed. Magna, 77-115.

Mo, K. C., R. W. Higgins 1998: Tropical convection and precipitation regimes in the western United States. - *J. Climate* **11**, 2404– 2423.

Molgedey L., W. Ebeling, 2000: Local order, entropy and predictability of financial time series, *Eur. Phys. J B* 15 733-737.

Müller G., Nuñez M, Seluchi M, 2000: Relationship between ENSO cycles and frosts events within the Pampa Húmeda region. *Int. J. of Climatol.* 20,1619-1637

Müller G., Compagnucci R., Núñez M, Salles, A., 2003: Surface Circulation associated with frost in the wet Pampas. *Int. J. of Climatol.* 23, 943-961.

Naumann, G., 2006: Estimación Y Análisis De Tendencias Sobre La Temperatura Máxima y Mínima En Series De Referencia En El Sudeste De Sudamérica. Aspectos Metodológicos e Inferencias En Escala Diaria. Tesis de licenciatura. FCEyN – UBA.

Naumann G., W. M. Vargas y J. L. Minetti, 2007: Análisis de la Variabilidad intraestacional de la temperatura en Sudamérica y su relación con la oscilación de Madden-Julian. XVI Congreso Mexicano de Meteorología - Veracruz, México.

Naumann, G. and W. M. Vargas, 2009: Changes in the predictability of the daily thermal structure in southern South America using information theory, *Geophys. Res. Lett.*, 36, L09704, doi:10.1029/2009GL037576. ISSN 0094–8276

Nicolis, C., Ebeling, W., Baraldi, C., 1997: Markov processes, dynamic entropies and the statistical prediction of mesoscale weather regimes. *Tellus*, 49A, 10-118.

Otnes, R.K. and L. Enochson, 1972: *Digital Time Series Analysis*. University Software Systems. John Wiley & Sons. New York.

Palmer T and R. Hagedorn, 2006: *Predictability of Weather and Climate*. Published by Cambridge University press.

Park, J., and M.E. Mann, 2000: Interannual temperature events and shifts in global temperature: A multiple wavelet correlation approach.- *Earth Interactions* 4-1, 1-53pp.

Percival DB, Walden AT. 2000. *Wavelet Methods for Time Series Analysis*. Cambridge University Press: Cambridge.

Pearson, K., 1901: On lines and planes of closest fit to systems of points in space. *Philosophical Magazine* 2:559-572.

Percival DB, Walden AT., 2000: Wavelet Methods for Time Series Analysis. Cambridge University Press: Cambridge.

Peterson TC, Easterling DR, Kart TR, Groisman P, Nicholls N., Plummer N., Torok S., Auer I., Böhm R., Gullet D., Vicent L., Heino R., Tuomenvirta H., Mestre O., Szentimrey T., Salinger J., Førland EJ., Hanssen – Bauer I., Alexandersson H., Jones P., Parker D., 1998: Homogeneity adjustments of in situ atmospheric climate data: a review. *International Journal of Climatology* 18: 1493-1517

Renwick, J. A., and J. M. Wallace, 1995: Predictable anomaly patterns and the forecast skill of Northern Hemisphere wintertime 500-mb Height fields. *Mon. Wea. Rev.*, **123**, 2114-2131.

Roulston, M.S., and L.A. Smith, 2002: Evaluating Probabilistic Forecasts Using Information Theory. *Mon. Wea. Rev.*, 130, 1653–1660.

Russell J.S., 1984: Mathematical representation of related periodic variables using Fourier series and projections of vectors functions: application to the biological sciences. *Agricultural and Forest Meteorology*, 30, 215-224.

Rusticucci, M., Vargas, W, 1993: Las Temperaturas de Bulbo Seco y Húmedo en la Argentina. Valores medios y persistencia de anomalías, *Meteorológica*, Vol 18, Nos. 1 y 2, 39-47.

Rusticucci, M., Vargas, W, 1995: Synoptic Situations related to Spells of Extreme Temperatures over Argentina, *Meteorological Applications*, Vol 2, 291-300.

Rusticucci, M. y Barrucand, M. G., 2001: Climatología de temperaturas extremas en la Argentina. Consistencia de datos. Relación entre la temperatura media estacional y la ocurrencia de días extremos.

Rusticucci, M. y W. Vargas, 2001: Interannual variability of Temperature Spells over Argentina, *Atmósfera*, Vol 14: 75-86.

Rusticucci, M, Vargas, W. 2002: Cold and warm events over Argentina and their relationship with the ENSO phases: Risk evaluation analysis. *Int. J. of Climatology*, vol 22, 467-483.

Rusticucci y Barrucand, 2004: Observed Trends and Changes in Temperature Extremes over Argentina. *Journal of Climate* 17, pags. 4099-4107

Scian B. V., 1970: Situación sinóptica asociada a las temperaturas extremas observadas en junio de 1967. *Meteorologica* Vol 1, 22-37.

Sellers, W.K., 1965: *Physical Climatology*, University of Chicago Press, Chicago.

Seo K, Wang W, Gottschalck J, Zhang Q, Schemm J, Higgins WR, Kumar A, 2009: Evaluation of MJO Forecast Skill from Several Statistical and Dynamical Forecast Models. *Journal of Climate* 22(9): 2372

Shannon C.E., 1948: A mathematical theory of communication," *Bell System Technical Journal*, vol. 27, pp. 379-423 and 623-656.

Shannon, C. E., 1950: Prediction and entropy of printed English, *The Bell System Technical Journal*, 30:50-64.

Schneider, T. and S. M. Griffies, 1999: A conceptual framework for predictability studies. *J.Climate*, **12**, 3133-3155.

Shukla, J., 1981a: Dynamical predictability of monthly means. *J. Atmos. Sci.*, **38**, 2547–2572.

Shukla, J., 1981b: *Predictability of the Tropical Atmosphere*. NASA Technical Memorandum 83829. Goddard Space Flight Center, Greenbelt, MD.

Shukla, J., 1998: Predictability in the Midst of Chaos: A Scientific Basis for Climate Forecasting. *Science*, 282, 728-731.

Simmons, A. J. and A. Hollingsworth, 2002: Some aspects of the improvement in skill of numerical weather prediction, *Q. J. R. Meteorol. Soc.*, **128**, 647-677.

Sneyers, R., 1990: On the statistical analysis of series of observations. WMO Technical Note 143. WMO No. 415, TP-103, Geneva, World Meteorological Organization, pp: 192.

Sneyers, R., 1992: On the use of statistical analysis for the objective determination of climate change. *Meteorol. Zeitschrift*, N. F. 1, 247-256 (Oktober 1992)

Sneyers, R., 1995: Climate Instability determination a Review. Climate dynamics and the global change perspectives. 17-20 October 1995, Cracow, Poland.

Stine, A. R., P. Huybers, I. Y. Fung, 2009: Changes in the phase of the annual cycle of surface temperature. *Nature* 457, 435-440 (22 January 2009) | doi:10.1038/nature07675

Straus, D. M. and J. Shukla, 1981: Global and local fluctuations of winter and summer simulations with the GLAS climate model. NASA Tech. Memo. 83907, pp. 231-236.

Straus, D. M., 1983: On the role of the seasonal cycle. *J. Atmos. Sci.*, 40, 303-313.

Tang, Y., R. Kleeman, and A.M. Moore, 2008: Comparison of Information-Based Measures of Forecast Uncertainty in Ensemble ENSO Prediction. *J. Climate*, 21, 230–247.

Tien-Yien L. and J. A. Yorke, 1975: Period Three Implies Chaos Source: *The American Mathematical Monthly*, Vol. 82, No. 10, pp. 985-992

Torrence, C., G.P. Compo, 1998: A Practical Guide to Wavelet Analysis. - *Bull. Amer. Meteor. Soc.* 79, 61–78.

Trenberth, K., 1984a. some effects of finite sample size and persistence on meteorological statistics. Part I: Autocorrelations. *Mon Wea Rev.* 112, 2359-2368.

Trenberth, K., 1984b: some effects of finite sample size and persistence on meteorological statistics. Part I: Potential predictability. *Mon Wea Rev.* 112, 2369-2379.

Vargas W. M. y A.P. Alessandro, 1983: Las distribuciones de secuencias secas, lluviosas, cálidas y frías en las series climáticas del nordeste argentino. *Meteorológica*, Vol XIV, N°1 y N°2. Argentina.

Vargas, W. M. y Ruiz, N. E., 1993: Estudio de los procesos estadísticos en series de presión diaria en las Islas Orcadas del Sur. Parte II: autocorrelogramas y espectros. *Revista Geofísica* 38, 123-140.

Vargas W.M., J.L. Minetti, A.G. Pobrete, 2002: Low-frequency oscillations in climatic and hydrological variables in southern South America's tropical-subtropical regions. *Theor. Appl. Climatol.* 72, 29-40.

Vargas W. M., Naumann G. y Minetti J. L., 2006: Las Tendencias de la temperatura máxima y mínima en Series de Referencia del Sudeste de Sudamérica. Aspectos metodológicos. *Revista de Geografía*. Año VIII, N° 10, 67-74.

Vargas W. M., G. Naumann, 2008: Impacts Of Climatic Change And Low Frequency Variability In Reference Series On Daily Maximum And Minimum Temperature In Southern South America. *Regional Environmental Change*. Vol. 8 N° 2 45-87.

Vecchi G. A. and N. A. Bond, 2004 The Madden-Julian Oscillation (MJO) and northern high latitude wintertime surface air temperatures. - *Geophysical Research Letters*, Vol. **31**, doi:10.1029/2003GL018645.

Vera, C. y P. Vigliarolo, 2000: A diagnostic study of cold-air outbreaks over South America, *Monthly. Weather Review*, Vol 128, 3-24.

Venzke, S., M. R. Allen, R. T. Sutton, and D. P. Rowell, 1999: The atmospheric response over the North Atlantic to decadal changes in sea surface temperature. *J. Climate*, **12**, 2562-2584.

Wei, W.W.S., 1993: *Time Series Analysis: Univariate and Multivariate Methods*. Publisher by Addison-Wesley.

Werner PC, Gerstengarbe FW, Ebeling W, 1999: Changes in probability of sequences, exit time distribution and dynamical entropy in Potsdam temperature record. *Theor Appl Climatol* 62:125–132.

Wheeler, M.C., and H.H. Hendon, 2004: An All-Season Real-Time Multivariate MJO Index: Development of an Index for Monitoring and Prediction. *Mon. Wea. Rev.*, **132**, 1917–1932.

Wijngaard, J., Klein Tank A. and Können G. 2003: Homogeneity of 20TH Century European Daily Temperature and Precipitation Series. *International Journal of Climatology* 23: 679-692

Wilks, D. S., 2002: *Statistical Methods in the Atmospheric Sciences*. Academic Press, 467 pp.

Williams, W. T. y Dale M. B., 1965: Fundamental Problems in Numerical Taxonomy. *Adv. Bot. Res.*, **2**, 35.

Yamamoto, R., Iwashima, T., Kadi S. N. y Osilla, M. 1985: Climatic Jump: A Hypothesis in Climate Diagnostic. *J. Met. Soc. of Japan*, 63, 1157-1160.

Zha H., C. Ding, M. Gu, X. He and H.D. Simon, 2001: "Spectral Relaxation for K-means Clustering", *Neural Information Processing Systems*, 14 1057-1064, Vancouver, Canada.

Zhang, C. 2005: Madden-Julian Oscillation. - *Reviews of Geophysics* **43**, 1-36.

Zhou, S., and A.J. Miller, 2005: The Interaction of the Madden-Julian Oscillation and the Arctic Oscillation. - *J. Climate* **18**, 143-159.

ANEXO I

años	Campinas		Tucumán		Corrientes		Pergamino		Pilar		Buenos Aires		Santa Rosa		Río Gallegos	
	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn
1890	0	0														
1891	0	0														
1892	100	45	0	44												
1893	84	53	0	0												
1894	0	0	0	0												
1895	35	0	0	0												
1896	26	0	49	96	10	80										
1897	34	0	21	29	52	40									0	0
1898	21	0	8	0	58	73									44	45
1899	27	86	0	0	0	0									0	0
1900	0	0	16	0	0	0									0	0
1901	0	21	0	0	0	0									0	0
1902	15	9	43	59	0	0									0	93
1903	0	18	0	0	0	0					0	0			23	24
1904	0	0	0	51	55	34					0	0			0	0
1905	0	58	0	59	0	47					0	0			0	32
1906	0	29	0	0	0	0					0	0			0	0
1907	25	0	0	0	0	0					0	0			80	97
1908	0	0	0	39	0	0					25	0			64	0
1909	0	0	0	0	0	0					34	0			0	0
1910	0	0	38	0	0	0					0	0			17	7
1911	0	0	33	0	0	0					0	0			0	0
1912	80	62	0	114	40	44					0	61			0	0
1913	0	0	0	26	0	0					0	0			0	0
1914	0	0	0	93	90	63					91	20			0	0
1915	0	24	0	0	0	0					44	41			0	0
1916	84	90	15	0	0	0					63	70			0	0
1917	0	0	0	0	0	0					65	57			0	0
1918	0	0	64	58	50	44					1	55			0	0
1919	0	42	0	46	0	0					0	0			0	0
1920	74	49	0	59	0	59					0	103			0	0
1921	0	0	0	0	0	31					0	47			0	0
1922	0	0	0	0	26	0					0	0			0	0
1923	0	0	43	18	93	27					47	41			0	0
1924	0	61	0	0	0	0					0	0			0	0
1925	0	0	25	0	27	26					66	25			0	0
1926	0	0	0	0	77	25					0	0			0	0
1927	0	0	0	0	0	0					0	0			0	0
1928	0	0	0	0	0	0					0	0			0	9
1929	0	0	0	92	75	87					0	59			0	11
1930	0	0	0	0	45	62					0	0			0	0
1931	38	13	0	0	45	62	0	126	0	39	0	105			51	0
1932	0	0	0	0	0	0	0	22	7	0	0	0			0	0
1933	0	0	0	0	0	0	12	13	0	0	0	0			51	0
1934	0	0	0	0	0	38	22	0	0	0	0	0			0	41
1935	0	0	0	0	0	11	88	65	51	88	43	39			26	0
1936	67	58	58	0	41	0	44	45	82	63	0	0			12	0
1937	0	0	0	0	0	0	64	0	36	0	0	0	0	0	55	0
1938	61	0	43	0	36	37	99	0	56	0	2	0	44	0	84	0
1939	16	0	0	38	55	78	75	91	44	31	67	0	0	0	0	0
1940	19	0	0	0	0	0	0	0	15	29	0	0	0	0	0	0
1941	0	71	22	59	0	0	59	41	70	75	34	32	92	96	0	0
1942	0	0	0	0	0	0	74	12	70	0	38	0	100	53	0	19
1943	0	0	0	0	0	0	0	45	0	42	0	0	0	14	0	22
1944	0	0	0	0	0	0	0	0	27	0	19	0	14	0	30	0
1945	0	0	0	0	0	0	0	0	0	0	0	0	22	29	0	0
1946	0	0	0	21	0	0	0	0	0	58	0	0	0	11	0	0
1947	0	97	0	0	0	0	0	33	0	57	0	0	0	85	0	0
1948	0	0	41	27	0	0	0	73	0	64	0	0	0	0	0	0
1949	4	0	0	26	83	62	72	107	34	48	36	55	46	92	17	0
1950	0	54	47	103	0	52	147	85	127	158	38	70	118	150	0	0
1951	0	0	0	70	76	90	93	99	122	97	79	84	0	0	0	0
1952	52	0	65	69	37	31	134	70	161	84	100	44	0	0	0	0
1953	0	0	0	54	50	0	68	75	47	62	35	29	0	56	0	0
1954	20	0	29	46	0	0	82	62	49	86	0	65	147	73	51	74
1955	0	0	0	32	61	64	0	0	11	105	31	0	19	68	56	51
1956	0	60	0	0	0	0	0	0	0	46	0	0	50	0	0	0
1957	0	101	0	0	18	15	13	21	0	0	0	0	0	23	0	0
1958	28	0	0	0	0	0	69	0	0	0	0	17	0	115	0	0

1959	0	74	0	0	0	18	0	20	0	0	0	0	0	0	0	0
1960	0	0	0	55	66	0	91	138	84	57	0	0	0	0	0	0
1961	0	0	0	29	0	0	50	80	0	0	0	35	0	0	0	0
1962	23	0	0	0	0	0	32	65	9	63	4	48	9	0	0	0
1963	0	21	0	46	59	64	104	76	71	114	68	64	0	71	0	0
1964	22	12	0	19	0	121	0	74	0	142	0	0	0	0	0	0
1965	0	41	0	69	49	68	0	0	99	102	60	64	43	47	64	61
1966	30	111	22	86	0	0	14	0	44	15	18	0	36	0	102	33
1967	61	0	0	40	0	55	43	104	61	73	6	0	0	0	33	0
1968	0	36	0	0	0	0	0	0	0	0	0	0	0	0	47	0
1969	0	51	0	57	61	26	82	74	51	137	0	41	0	109	6	0
1970	0	0	0	0	0	0	28	0	55	0	0	0	13	30	0	0
1971	0	0	0	0	0	0	9	45	0	0	0	0	24	0	0	0
1972	54	0	0	76	48	58	39	65	0	75	0	41	18	48	0	0
1973	96	133	43	0	63	94	102	46	173	0	0	0	120	22	0	74
1974	25	137	0	7	0	0	0	67	74	5	0	46	41	81	44	34
1975	0	0	0	26	0	0	0	0	0	68	0	0	0	79	57	0
1976	79	0	75	119	124	106	138	83	119	109	114	74	118	0	19	0
1977	0	0	0	0	0	0	116	140	63	111	44	0	115	55	0	28
1978	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1979	0	41	41	0	33	20	62	88	93	57	0	0	0	63	0	0
1980	0	0	0	0	0	0	22	0	0	0	0	0	0	0	38	0
1981	0	0	0	15	0	46	0	100	0	45	0	43	0	49	0	0
1982	0	0	0	22	23	69	80	55	114	73	0	60	102	37	33	0
1983	26	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1984	16	48	0	78	0	63	105	74	88	85	22	0	46	55	45	106
1985	131	86	0	84	64	130	57	87	0	117	0	89	17	105	0	0
1986	0	54	0	0	53	0	57	61	56	40	14	0	0	66	0	0
1987	15	72	0	41	25	86	40	191	0	190	0	138	28	170	0	0
1988	0	0	0	43	0	22	75	18	76	75	31	0	96	57	0	45
1989	0	0	0	72	0	0	62	51	62	9	0	26	68	31	0	0
1990	26	128	0	109	52	84	65	105	49	146	45	76	7	99	0	0
1991	0	0	4	0	0	0	0	0	62	0	0	0	0	0	0	0
1992	0	0	0	69	0	0	0	65	0	37	0	0	0	13	77	30
1993	0	26	20	0	0	0	71	0	78	0	35	0	128	0	0	0
1994	0	0	0	15	59	61	0	20	0	35	0	0	0	0	0	0
1995	24	0	0	0	34	124	0	0	29	91	0	0	30	32	54	0
1996	0	11	0	0	66	109	82	118	65	75	0	44	117	56	0	0
1997	0	0	0	0	0	0	70	124	20	86	0	19	92	152	0	23
1998	38	54	0	0	0	0	0	0	0	0	0	0	0	18	0	0
1999	25	87	0	0	58	0	79	0	67	0	33	0	57	73	0	0
2000	0	0	0	0	0	0	44	0	75	0	0	0	60	0	0	24
2001	83	15	0	34	72	80	0	0	43	81	29	0	47	34	0	0
2002	0	34	0	19	0	0	0	0	57	0	0	0	26	20	55	0
2003	0	0	0	41	0	72	0	0	0	59	0	0	0	19	17	0
2004	0	0	0	47	54	41	0	0	73	104	7	0	101	45	11	0
2005	0	0	0	0	66	0	0	0	0	0	102	0	0	0	32	19
2006	0	0	0	0	35	0	0	0	0	0	0	0	0	0	0	0
2007	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Tabla I-1. Cantidad de días por año con cuasi-periodicidades de 33 días con densidad espectral wavelet significativa al 95% para la Temperatura máxima (Tx) y mínima (Tn) sobre las estaciones de referencia.

años	Campinas		Tucumán		Corrientes		Pergamino		Pilar		Buenos Aires		Santa Rosa		Río Gallegos	
	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn
1890	0	18														
1891	58	0														
1892	0	110														
1893	0	91	0	0	0	0										
1894	45	0	0	69	134	113									0	0
1895	147	0	0	79	0	0									0	0
1896	5	0	0	46	0	64									0	0
1897	0	162	0	0	0	0									36	45
1898	0	88	16	0	70	87									0	28
1899	78	51	0	81	96	99									0	0
1900	0	0	0	0	0	0									0	0
1901	0	0	0	0	0	0									0	0
1902	161	107	46	83	0	0									0	119
1903	168	0	0	0	23	0					0	0			0	0
1904	0	0	0	0	0	0					0	0			0	0
1905	0	94	0	0	0	0					0	0			0	0
1906	61	0	0	0	0	107					0	70			0	117
1907	129	17	0	42	101	126					0	0			63	108
1908	0	0	0	0	0	0					0	0			0	0
1909	0	0	0	33	0	81					0	0			0	0
1910	0	0	0	0	33	56					59	65			0	0
1911	0	0	63	0	0	0					0	69			0	0
1912	0	27	0	37	78	117					0	0			0	33
1913	0	0	0	0	0	0					0	0			0	0
1914	0	0	0	0	0	28					0	29			0	0
1915	0	0	0	0	0	26					0	65			0	38
1916	23	0	0	0	12	0					0	0			0	1
1917	0	0	0	0	10	0					0	0			0	0
1918	0	60	0	96	53	106					50	110			0	0
1919	0	0	0	0	0	25					0	0			0	0
1920	0	0	0	0	0	0					0	0			0	0
1921	0	150	0	0	0	0					0	0			0	0
1922	0	0	0	0	0	0					0	0			0	0
1923	0	87	20	72	48	0					107	0			0	0
1924	0	70	0	60	0	0					0	66			0	0
1925	69	0	49	0	91	41					36	61			0	0
1926	0	0	0	66	0	104					0	50			0	0
1927	0	0	0	0	0	0					0	0			0	0
1928	0	0	0	19	28	0					64	74			0	0
1929	42	0	0	0	0	0					0	0			0	0
1930	0	0	60	105	143	149					23	0			27	36
1931	74	34	0	63	0	45	0	0	55	52	0	0			0	0
1932	0	0	0	0	0	0	0	0	72	0	0	0			0	41
1933	0	0	0	0	0	0	0	0	0	0	0	0			77	0
1934	0	13	0	0	0	0	0	0	0	0	0	0			58	0
1935	7	0	0	0	0	80	149	90	0	48	0	0			0	0
1936	0	0	70	0	0	0	0	70	0	47	0	59			101	68
1937	0	0	45	103	83	129	126	157	67	147	83	129	0	0	76	0
1938	0	0	0	0	0	0	148	0	0	0	0	0	52	0	0	0
1939	0	0	0	0	66	0	0	0	0	4	1	0	0	0	0	0
1940	0	0	0	25	0	0	0	0	0	53	22	0	30	0	0	0
1941	23	171	16	18	0	0	107	26	66	82	85	0	126	0	0	0
1942	0	0	0	0	0	0	31	0	0	0	0	0	0	0	0	0
1943	0	0	0	0	0	0	58	0	19	0	0	0	34	0	45	42
1944	0	0	25	69	0	0	154	29	163	92	47	0	140	127	78	0
1945	0	0	0	0	0	0	0	0	33	111	0	0	2	13	0	0
1946	21	99	0	0	0	0	86	177	187	123	136	126	123	172	0	0
1947	0	0	0	0	0	0	21	49	12	14	8	26	5	5	0	0
1948	0	40	0	0	0	0	0	42	0	27	0	0	0	0	0	63
1949	70	0	0	0	0	0	44	0	0	0	0	0	42	0	0	0
1950	0	0	93	0	0	0	112	0	59	32	37	0	0	0	0	0
1951	0	26	0	71	0	31	109	129	65	155	69	75	0	0	0	0
1952	48	67	0	55	56	96	41	84	78	117	41	0	0	0	0	0
1953	0	0	0	0	0	0	165	79	60	0	61	0	0	0	0	0
1954	0	0	0	0	0	0	0	126	0	46	0	0	0	0	52	0
1955	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	84
1956	0	0	0	0	0	0	0	0	0	57	0	39	0	18	16	0
1957	10	64	0	146	132	123	191	0	0	0	127	0	122	90	29	0
1958	118	0	0	0	0	0	148	0	0	0	0	0	139	0	0	53
1959	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1960	0	0	0	27	0	0	0	44	0	48	0	0	0	0	0	0

1961	0	0	0	18	0	0	0	0	0	0	0	0	0	0	0	0	0
1962	0	0	0	0	0	0	159	0	0	0	58	65	157	36	0	0	0
1963	0	0	0	90	80	105	54	152	36	155	0	0	49	90	0	0	0
1964	0	0	0	0	0	0	0	72	0	74	0	22	0	0	0	72	0
1965	89	0	110	82	82	79	0	0	217	109	120	95	215	118	110	0	0
1966	0	0	0	0	0	0	0	0	46	0	80	0	124	0	0	0	0
1967	69	0	89	136	116	169	122	145	103	160	89	131	106	103	0	0	0
1968	38	0	0	0	0	0	23	0	0	0	0	0	72	37	0	0	0
1969	0	56	30	0	87	0	158	34	113	39	0	0	27	53	0	0	0
1970	0	53	0	137	171	134	243	257	135	258	129	162	196	197	0	0	0
1971	0	65	0	102	92	217	157	186	130	219	92	82	129	94	26	0	0
1972	32	0	0	111	91	101	51	72	37	109	62	0	131	40	0	0	0
1973	0	109	0	0	0	68	0	85	0	18	0	37	0	0	0	0	0
1974	0	43	0	75	26	69	62	143	0	101	59	109	0	108	0	37	0
1975	0	84	0	0	0	0	0	64	9	82	0	0	29	62	74	0	0
1976	0	0	0	0	0	4	0	0	0	15	0	0	0	68	111	62	0
1977	0	0	0	88	142	52	73	89	72	98	32	16	113	106	45	0	0
1978	0	0	0	52	0	156	0	75	0	81	0	0	0	0	34	0	0
1979	46	159	0	0	0	83	0	0	0	86	0	0	0	0	0	0	0
1980	0	0	0	0	0	0	0	0	0	0	0	0	0	0	22	0	0
1981	0	0	0	0	0	63	0	78	0	59	0	41	74	0	0	0	0
1982	0	0	68	0	81	0	74	84	128	0	0	0	102	0	85	67	0
1983	159	80	0	0	76	134	0	0	0	0	0	0	0	0	13	0	0
1984	0	0	64	0	78	0	131	0	124	26	115	0	125	27	0	0	0
1985	121	27	12	0	0	0	13	0	19	0	22	0	58	65	0	0	0
1986	5	0	0	0	0	0	0	0	9	0	0	0	0	0	38	0	0
1987	33	91	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1988	0	64	0	0	0	111	0	0	0	0	0	0	0	27	207	143	0
1989	0	0	0	45	0	0	0	30	0	0	0	0	58	0	0	0	0
1990	0	75	0	80	38	68	133	95	103	100	79	42	105	109	0	0	0
1991	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	62	0
1992	0	0	0	13	0	75	85	122	72	104	0	36	79	121	0	0	0
1993	0	0	0	0	0	0	0	0	0	0	0	0	27	0	0	0	0
1994	0	0	0	0	0	0	0	28	0	57	0	0	77	0	77	63	0
1995	0	0	0	45	32	0	68	0	114	61	0	0	173	0	0	0	0
1996	0	0	0	0	0	0	0	32	0	50	0	0	135	111	0	0	0
1997	0	37	0	0	0	0	13	0	0	0	0	0	35	0	12	0	0
1998	0	0	0	0	0	0	0	0	0	0	0	0	59	0	0	0	0
1999	0	99	0	0	93	42	37	57	127	64	0	0	45	0	0	0	0
2000	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2001	0	97	0	100	102	111	0	0	104	136	89	69	105	103	0	78	0
2002	24	56	0	31	0	76	0	0	44	188	32	51	0	47	39	0	0
2003	0	109	0	46	0	47	0	0	0	105	0	0	65	59	0	0	0
2004	0	0	0	0	0	0	0	0	0	0	0	0	69	0	0	0	0
2005	0	0	0	0	0	0	0	0	0	0	68	19	0	0	70	54	0
2006	0	0	0	0	0	0	0	0	0	0	11	0	0	0	47	68	0
2007	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Tabla I-2. Cantidad de días por año con cuasi-periodicidades de 45 días con densidad espectral wavelet significativa al 95% para la Temperatura máxima (Tx) y mínima (Tn) sobre las estaciones de referencia.

años	Campinas		Tucumán		Corrientes		Pergamino		Pilar		Buenos Aires		Santa Rosa		Río Gallegos	
	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn
1890	0	181														
1891	0	0														
1892	0	143														
1893	0	136	0	127												
1894	57	0	0	0	0	11										
1895	58	0	0	144	0	54										
1896	0	0	0	40	0	0									0	0
1897	0	181	0	0	0	0									42	0
1898	0	118	0	0	0	111									0	0
1899	0	0	16	79	79	137									0	0
1900	0	0	0	0	0	0									0	0
1901	0	0	94	0	0	0									0	0
1902	189	62	44	91	0	0									0	168
1903	175	0	0	14	19	0									0	0
1904	0	0	0	0	0	0					0	0			0	0
1905	0	0	0	0	0	0					0	0			69	0
1906	0	0	0	0	81	94					71	80			8	146
1907	0	0	0	157	63	92					0	0			62	0
1908	0	0	0	0	0	0					0	0			0	0
1909	0	0	0	0	0	65					0	8			0	0
1910	0	76	0	0	52	67					47	0			5	0
1911	0	0	46	0	0	0					0	58			12	0
1912	0	0	0	91	59	0					0	0			54	88
1913	0	0	0	0	0	0					0	0			0	0
1914	0	0	0	0	0	0					0	0			0	0
1915	0	0	0	0	0	0					0	0			0	55
1916	89	0	0	0	0	0					0	0			0	12
1917	77	0	0	0	0	0					0	0			0	0
1918	0	70	0	43	0	0					0	0			0	0
1919	46	0	0	102	0	0					0	87			0	0
1920	0	0	0	0	0	0					0	0			0	0
1921	0	93	0	0	0	0					0	0			0	0
1922	0	0	0	108	0	0					0	0			0	0
1923	0	52	0	112	0	50					0	0			0	0
1924	0	0	0	76	0	0					0	0			0	0
1925	119	0	0	0	0	17					0	71			0	0
1926	0	0	0	0	0	0					0	0			0	0
1927	0	0	0	0	0	0					0	115			0	0
1928	0	0	0	0	0	0					0	0			0	0
1929	0	120	0	0	0	0					0	0			0	0
1930	0	0	49	105	78	103					38	0			0	67
1931	0	0	0	0	0	0	0	0	151	0	0	0			0	0
1932	0	0	0	0	0	0	0	0	0	0	0	0			0	0
1933	0	0	0	0	0	0	51	0	0	0	0	0			0	0
1934	0	0	0	0	0	0	39	0	0	0	0	0			0	48
1935	43	0	0	56	60	137	175	134	0	152	0	22			0	0
1936	0	0	0	0	0	0	0	33	0	0	0	0			64	13
1937	0	0	0	135	100	176	174	197	128	196	119	162	0	0	56	19
1938	0	0	0	0	0	0	0	0	43	0	0	0	0	0	0	0
1939	0	0	0	0	32	0	0	0	16	0	0	0	0	0	0	0
1940	5	0	0	0	0	0	0	0	0	0	21	0	0	0	0	0
1941	30	51	0	0	0	0	114	103	37	71	81	0	119	0	0	0
1942	0	98	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1943	0	0	0	0	0	0	77	0	0	0	0	0	129	0	51	44
1944	0	0	0	88	0	0	339	149	155	183	22	89	225	140	2	33
1945	0	0	0	0	0	0	89	31	0	59	74	0	51	0	0	0
1946	0	63	0	0	0	0	84	79	169	99	108	97	114	94	0	0
1947	0	0	0	0	0	0	7	0	0	5	2	0	18	0	0	0
1948	0	104	0	0	0	0	11	136	12	143	0	63	0	0	67	0
1949	92	0	0	0	0	0	64	0	6	0	0	0	94	0	0	0
1950	0	0	117	78	113	101	135	74	140	98	88	0	128	63	0	0
1951	0	0	0	0	0	0	43	0	0	45	0	0	0	0	0	0
1952	60	90	0	108	108	117	86	65	140	124	0	0	0	0	0	0
1953	0	0	0	0	0	0	82	0	78	0	0	0	0	0	1	0
1954	0	0	0	0	0	0	0	78	0	60	0	0	53	0	41	0
1955	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	38
1956	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1957	0	0	0	33	105	88	58	0	0	0	158	51	129	89	0	0
1958	79	0	0	0	0	0	206	121	0	0	0	53	92	68	22	52

1959	0	37	0	0	0	0	0	0	0	0	0	0	105	0	0	0
1960	0	0	0	34	0	0	39	76	0	81	0	0	0	0	0	0
1961	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1962	0	0	0	0	0	0	0	0	0	0	0	0	57	0	0	0
1963	0	0	0	0	0	114	0	127	0	111	0	0	48	92	0	0
1964	0	0	0	0	0	0	0	92	115	107	0	0	68	0	99	
1965	146	0	185	192	193	173	0	212	191	190	133	241	328	98	26	
1966	0	103	0	0	0	0	0	0	0	0	0	0	12	0	76	51
1967	0	0	0	112	47	138	110	146	82	163	84	101	103	137	0	0
1968	0	0	0	0	0	0	80	0	0	0	0	0	59	0	0	0
1969	0	0	0	0	76	0	17	77	48	110	0	0	28	16	0	0
1970	0	0	0	138	68	94	142	197	124	167	74	117	131	235	0	0
1971	0	0	0	244	270	263	215	243	173	263	140	171	186	127	0	0
1972	0	0	0	0	0	0	0	0	45	0	0	0	0	0	0	0
1973	0	63	0	0	0	0	0	74	0	0	0	0	0	0	0	0
1974	43	85	0	0	0	39	33	145	0	83	0	76	0	22	0	15
1975	0	24	0	0	0	0	0	48	0	98	0	0	114	61	133	0
1976	0	0	0	29	0	0	0	0	42	0	0	0	277	70	0	0
1977	0	0	0	0	0	0	0	0	77	0	0	0	0	0	131	0
1978	0	0	0	94	0	96	0	102	0	140	0	12	0	108	77	0
1979	60	150	0	0	0	74	27	0	0	0	0	0	0	16	0	0
1980	0	29	0	0	0	0	59	0	93	0	0	0	145	42	0	0
1981	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1982	0	0	57	0	55	0	55	0	231	0	0	0	0	0	131	102
1983	91	0	0	0	32	87	0	0	0	0	0	0	0	0	0	0
1984	0	0	0	0	101	0	0	0	0	0	0	0	0	0	0	0
1985	0	0	0	0	0	0	0	0	0	0	0	0	63	0	0	0
1986	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1987	0	63	0	0	0	0	0	0	36	0	0	0	0	0	0	0
1988	0	0	0	0	0	207	0	0	0	0	0	0	0	0	101	0
1989	0	0	0	133	0	0	0	0	126	0	0	0	75	113	0	0
1990	0	0	0	66	0	0	128	0	90	48	63	0	117	0	0	0
1991	0	0	0	0	0	25	0	0	52	0	0	0	93	0	70	0
1992	0	0	0	88	0	88	124	112	76	107	101	76	105	90	0	0
1993	0	0	0	0	0	0	0	0	0	0	0	0	30	0	0	0
1994	0	0	0	0	0	0	0	44	0	50	0	0	0	55	108	83
1995	0	0	103	67	77	0	77	0	162	89	0	0	83	0	0	0
1996	0	0	0	0	0	0	0	19	0	0	0	0	49	60	90	0
1997	120	108	0	0	0	0	0	0	0	0	0	0	6	0	0	0
1998	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1999	0	36	0	0	66	0	0	17	78	0	0	0	0	0	0	0
2000	0	60	0	0	0	125	0	0	0	0	0	0	0	0	0	0
2001	0	0	0	96	76	85	0	0	48	121	96	59	41	0	24	71
2002	164	160	0	0	0	62	0	0	0	107	0	0	100	0	103	0
2003	0	64	0	30	0	0	0	0	0	113	0	0	2	0	0	0
2004	0	0	0	0	0	0	0	0	55	0	0	0	28	0	0	0
2005	0	0	0	0	0	0	0	0	0	0	0	0	0	0	192	98
2006	0	0	0	0	0	0	0	0	0	0	0	0	0	0	126	100
2007	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Tabla I-3. Cantidad de días por año con cuasi-periodicidades de 55 días con densidad espectral wavelet significativa al 95% para la Temperatura máxima (Tx) y mínima (Tn) sobre las estaciones de referencia.

años	Campinas		Tucumán		Corrientes		Pergamino		Pilar		Buenos Aires		Santa Rosa		Río Gallegos	
	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn
1890	0	101	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1891	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1892	0	119	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1893	0	126	0	164	0	0	0	0	0	0	0	0	0	0	0	0
1894	76	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1895	128	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1896	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1897	0	76	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1898	0	19	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1899	0	0	0	0	0	155	0	0	0	0	0	0	0	0	0	0
1900	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1901	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1902	0	0	0	159	0	0	0	0	0	0	0	0	0	0	0	130
1903	38	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1904	0	0	0	0	0	0	0	0	0	0	0	0	0	0	56	78
1905	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1906	0	0	0	26	167	65	0	0	0	0	0	0	0	0	0	93
1907	0	0	0	170	0	0	0	0	0	0	0	0	0	0	89	0
1908	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1909	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1910	112	110	0	0	0	79	0	0	0	0	0	0	0	0	50	97
1911	0	0	0	0	0	0	0	0	0	0	0	29	0	0	48	0
1912	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	102
1913	0	0	0	0	0	0	0	0	0	0	0	46	0	0	0	0
1914	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1915	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	59
1916	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21
1917	0	0	0	0	0	0	0	0	0	0	0	55	0	0	0	0
1918	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1919	58	0	0	119	0	0	0	0	0	0	0	0	0	0	0	0
1920	0	55	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1921	0	0	0	59	0	64	0	0	0	0	0	0	0	0	0	0
1922	0	0	0	76	0	0	0	0	0	0	0	0	0	0	0	0
1923	0	0	0	100	103	68	0	0	0	0	0	39	0	0	0	0
1924	0	0	0	114	0	38	0	0	0	0	0	0	0	0	0	0
1925	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1926	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1927	0	0	0	0	0	21	0	0	0	0	0	78	0	0	0	0
1928	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1929	0	14	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1930	0	0	0	61	0	0	0	0	0	0	82	0	0	0	157	298
1931	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1932	0	0	0	0	0	13	121	37	107	0	55	0	0	0	0	0
1933	0	0	0	0	0	0	175	0	118	0	61	0	0	0	0	0
1934	61	0	0	0	52	113	82	136	0	0	0	70	0	0	0	0
1935	0	0	0	62	30	94	92	0	109	45	0	0	0	0	0	0
1936	0	0	0	0	0	0	0	0	0	0	0	0	0	0	135	55
1937	0	0	0	0	0	123	134	199	34	107	0	147	0	0	62	86
1938	0	0	0	0	0	0	0	0	85	0	0	0	107	0	0	0
1939	0	0	0	0	17	0	0	10	74	79	41	0	0	0	0	0
1940	52	0	0	0	0	0	0	0	0	0	53	0	0	0	0	0
1941	110	0	0	0	0	0	160	0	29	0	74	0	122	0	0	0
1942	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1943	0	0	0	0	0	0	224	131	92	0	93	0	232	204	0	0
1944	50	0	0	0	0	0	140	150	70	151	46	95	133	132	0	98
1945	0	0	0	0	0	0	171	19	0	0	100	0	159	0	0	0
1946	0	0	0	0	0	0	0	66	54	101	0	0	64	0	0	0
1947	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1948	0	135	0	0	0	0	40	151	27	156	0	143	0	0	91	0
1949	0	0	0	0	0	0	200	0	45	0	0	0	154	0	0	0
1950	0	0	0	36	124	124	73	0	27	72	0	0	69	31	0	0
1951	0	0	0	0	0	0	0	0	0	0	0	0	16	0	0	0
1952	147	183	0	98	100	122	164	56	170	161	77	26	0	0	0	0
1953	0	0	0	0	0	0	51	67	0	27	0	0	0	17	0	0
1954	0	0	0	0	0	0	0	76	0	235	0	101	0	239	0	0
1955	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1956	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1957	86	0	0	0	0	0	0	0	0	0	115	0	71	0	42	0
1958	0	0	19	92	0	0	236	160	0	0	92	120	62	144	143	0
1959	70	107	0	0	0	0	0	0	0	0	0	0	87	0	0	0
1960	0	0	0	0	0	0	0	0	0	44	0	0	0	0	0	0

1961	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1962	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1963	0	11	0	0	0	0	0	0	0	0	0	0	61	0	0	0
1964	0	78	0	0	0	0	0	179	0	135	0	0	0	118	66	97
1965	186	0	128	130	157	222	0	0	133	231	116	186	89	240	102	0
1966	0	59	0	0	0	0	0	0	0	0	0	0	0	0	61	0
1967	0	0	0	39	32	0	139	87	81	110	57	38	189	145	0	0
1968	0	0	0	0	54	0	113	0	0	0	0	0	85	0	0	0
1969	0	0	0	0	23	0	17	110	0	115	0	0	50	0	0	0
1970	0	0	0	0	0	99	121	0	124	0	0	0	96	0	0	0
1971	0	0	0	0	0	91	84	111	72	0	0	0	81	108	0	46
1972	0	71	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1973	0	0	0	0	0	0	24	97	0	0	0	0	35	0	0	0
1974	0	0	0	0	0	0	0	36	0	103	0	0	0	0	0	0
1975	0	0	0	0	0	0	119	80	98	144	75	0	160	112	22	0
1976	0	0	0	0	0	0	215	0	0	15	0	0	103	0	123	0
1977	0	0	0	0	0	0	0	0	0	0	0	0	56	0	154	0
1978	0	0	0	143	98	153	97	219	0	192	0	113	136	237	0	0
1979	0	0	0	54	0	79	116	0	66	0	0	0	133	0	0	0
1980	0	0	0	0	0	18	93	0	140	178	0	0	168	100	0	0
1981	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1982	0	0	0	0	0	0	0	0	86	0	0	0	0	0	0	89
1983	40	0	0	0	6	0	0	0	68	0	0	0	0	0	0	0
1984	0	0	0	0	181	0	0	0	0	0	0	0	0	0	0	0
1985	0	0	0	0	0	0	0	0	0	0	0	0	39	0	0	0
1986	0	0	0	0	0	0	0	102	0	116	0	0	0	0	0	0
1987	0	0	0	0	0	0	74	0	102	0	0	0	102	0	0	0
1988	0	0	0	0	0	0	0	0	45	0	0	0	0	0	0	0
1989	0	0	0	103	0	0	0	59	0	24	0	0	0	104	0	0
1990	21	0	0	0	0	0	70	0	0	0	0	0	115	0	0	0
1991	0	0	0	0	0	0	0	23	0	67	0	0	0	132	93	0
1992	0	0	0	67	0	77	112	109	0	92	32	63	143	73	112	0
1993	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1994	0	0	0	0	26	0	31	0	0	0	0	0	0	0	0	101
1995	0	0	0	0	133	0	0	0	117	33	0	0	0	0	0	0
1996	0	0	0	0	0	0	0	0	59	0	0	0	0	0	74	0
1997	136	138	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1998	0	0	0	0	0	0	49	0	51	0	0	0	0	0	0	0
1999	0	0	0	0	0	0	68	0	110	0	0	0	0	0	0	0
2000	0	0	0	0	0	146	0	0	0	0	0	0	0	0	0	0
2001	0	0	0	82	150	0	0	0	0	129	0	84	0	178	0	93
2002	168	110	0	0	38	0	0	0	0	114	0	0	91	0	88	0
2003	0	0	0	0	0	0	0	0	19	1	0	0	0	0	0	0
2004	0	0	0	0	145	137	0	0	73	121	77	82	0	105	56	0
2005	0	0	0	0	0	0	0	0	0	0	0	0	0	0	57	0
2006	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	12
2007	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Tabla I-4. Cantidad de días por año con cuasi-periodicidades de 66 días con densidad espectral wavelet significativa al 95% para la Temperatura máxima (Tx) y mínima (Tn) sobre las estaciones de referencia.

años	Campinas		Tucumán		Corrientes		Pergamino		Pilar		Buenos Aires		Santa Rosa		Río Gallegos	
	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn	Tx	Tn
1890	0.00	0.00														
1891	0.00	0.00														
1892	2.24	3.37														
1893	1.77	2.41														

1965	0.00	2.03	0.00	3.54	3.30	3.38	0.00	0.00	3.71	4.14	3.70	3.69	3.11	4.38	2.41	1.92
1966	1.67	2.06	1.59	1.88	0.00	0.00	1.36	0.00	1.88	1.58	2.03	0.00	2.09	0.00	2.09	1.75
1967	2.10	0.00	0.00	3.08	0.00	3.93	3.24	4.12	2.85	4.30	2.46	0.00	0.00	0.00	1.69	0.00
1968	0.00	1.95	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.66	0.00
1969	0.00	2.11	0.00	1.75	2.26	1.50	2.22	2.09	2.07	2.35	0.00	1.81	0.00	2.36	1.61	0.00
1970	0.00	0.00	0.00	0.00	0.00	0.00	2.69	0.00	2.55	0.00	0.00	0.00	2.46	2.49	0.00	0.00
1971	0.00	0.00	0.00	0.00	0.00	0.00	3.00	3.05	0.00	0.00	0.00	0.00	2.75	0.00	0.00	0.00
1972	2.42	0.00	0.00	2.57	2.31	2.31	2.16	1.98	0.00	2.75	0.00	1.43	2.24	1.69	0.00	0.00
1973	1.84	2.87	1.62	0.00	1.62	2.50	1.79	2.92	2.13	0.00	0.00	0.00	1.78	1.90	0.00	2.19
1974	1.75	2.42	0.00	1.98	0.00	0.00	0.00	4.23	1.72	3.00	0.00	3.18	1.57	2.58	1.28	2.21
1975	0.00	0.00	0.00	2.19	0.00	0.00	0.00	0.00	0.00	3.48	0.00	0.00	0.00	2.87	2.05	0.00
1976	2.39	0.00	1.80	2.23	2.08	2.81	2.24	2.45	1.99	2.55	1.71	1.59	2.10	0.00	2.57	0.00
1977	0.00	0.00	0.00	0.00	0.00	0.00	2.71	2.47	1.89	2.77	2.04	0.00	2.68	2.37	0.00	1.43
1978	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
1979	0.00	2.91	1.09	0.00	1.59	2.27	2.31	1.92	1.62	2.35	0.00	0.00	0.00	2.03	0.00	0.00
1980	0.00	0.00	0.00	0.00	0.00	0.00	2.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.85	0.00
1981	0.00	0.00	0.00	1.55	0.00	2.18	0.00	2.03	0.00	1.94	0.00	1.63	0.00	1.79	0.00	0.00
1982	0.00	0.00	0.00	1.41	1.91	1.58	2.23	1.91	2.81	1.65	0.00	1.55	2.23	1.48	2.16	0.00
1983	2.40	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
1984	1.44	1.12	0.00	2.12	0.00	1.83	2.88	2.19	2.20	2.63	2.11	0.00	2.28	1.99	1.77	2.25
1985	1.84	2.40	0.00	1.43	1.57	2.07	1.98	1.71	0.00	2.21	0.00	1.58	2.33	1.71	0.00	0.00
1986	0.00	1.74	0.00	0.00	1.47	0.00	1.73	1.29	2.30	1.53	1.68	0.00	0.00	1.57	0.00	0.00
1987	1.94	2.48	0.00	1.51	1.20	2.18	1.46	1.91	0.00	2.10	0.00	1.42	1.86	1.84	0.00	0.00
1988	0.00	0.00	0.00	1.50	0.00	2.79	1.27	1.75	1.56	1.71	1.09	0.00	1.68	1.94	0.00	1.94
1989	0.00	0.00	0.00	2.40	0.00	0.00	2.09	2.23	2.06	2.22	0.00	1.67	2.12	1.95	0.00	0.00
1990	1.60	2.20	0.00	2.65	2.16	2.77	3.46	3.11	2.95	3.13	2.52	2.36	2.44	3.18	0.00	0.00
1991	0.00	0.00	1.45	0.00	0.00	0.00	0.00	0.00	1.72	0.00	0.00	0.00	0.00	0.00	0.00	0.00
1992	0.00	0.00	0.00	2.47	0.00	0.00	0.00	3.04	0.00	2.80	0.00	0.00	0.00	2.50	2.39	1.72
1993	0.00	1.71	1.45	0.00	0.00	0.00	1.59	0.00	1.49	0.00	1.31	0.00	2.13	0.00	0.00	0.00
1994	0.00	0.00	0.00	1.78	2.00	2.10	0.00	2.05	0.00	2.09	0.00	0.00	0.00	0.00	0.00	0.00
1995	2.17	0.00	0.00	0.00	2.44	1.77	0.00	0.00	2.64	2.49	0.00	0.00	2.11	1.66	1.47	0.00
1996	0.00	1.81	0.00	0.00	1.51	2.14	1.72	2.43	1.66	2.29	0.00	1.71	2.58	2.15	0.00	0.00
1997	0.00	0.00	0.00	0.00	0.00	0.00	1.99	1.89	1.56	1.87	0.00	1.25	1.95	1.81	0.00	1.40
1998	1.27	1.73	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.68	0.00	0.00
1999	1.83	2.37	0.00	0.00	1.92	0.00	1.85	0.00	2.06	0.00	1.41	0.00	1.74	1.61	0.00	0.00
2000	0.00	0.00	0.00	0.00	0.00	0.00	1.60	0.00	1.75	0.00	0.00	0.00	1.92	0.00	0.00	1.27
2001	2.07	2.59	0.00	2.96	3.13	3.39	0.00	0.00	2.82	3.63	2.54	0.00	2.46	2.39	0.00	0.00
2002	0.00	2.47	0.00	1.77	0.00	0.00	0.00	0.00	1.96	0.00	0.00	0.00	2.03	1.74	2.41	0.00
2003	0.00	0.00	0.00	2.44	0.00	2.39	0.00	0.00	0.00	3.10	0.00	0.00	0.00	2.05	1.64	0.00
2004	0.00	0.00	0.00	1.18	1.43	2.25	0.00	0.00	1.46	1.97	1.57	0.00	1.91	1.74	1.45	0.00
2005	0.00	0.00	0.00	0.00	1.46	0.00	0.00	0.00	0.00	0.00	1.92	0.00	0.00	0.00	2.66	2.37
2006	0.00	0.00	0.00	0.00	1.24	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
2007	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00

Tabla I-5. Amplitud máxima anual asociadas a las cuasi-periodicidades con períodos entre 30 y 66 días para años con densidad espectral wavelet significativa al 95% para la Temperatura máxima (Tx) y mínima (Tn) sobre las estaciones de referencia.