

TESIS CARRERA DE DOCTORADO EN CIENCIAS DE
LA INGENIERÍA

PROCESAMIENTO ESTADÍSTICO DE SEÑALES EN
APLICACIONES DE RADAR METEOROLÓGICO

Mgter. Arturo Collado Rosell
Doctorando

Dr. Juan Pablo Pascual
Director

Dr. Javier Alberto Areta
Co-director

Miembros del Jurado

Dr.Santiago Hernández (Instituto Balseiro, CNEA-UNCuyo)

Dr.Jorge Lugo (Instituto Balseiro, Invap)

Dr.Ramón de Elia (Servicio Meteorológico Nacional (SMN))

Dra.Cecilia Galarza (CONICET, UBA)

Marzo 2022

Departamento de Ingeniería en Telecomunicaciones
Centro Atómico Bariloche

Instituto Balseiro
Universidad Nacional de Cuyo
Comisión Nacional de Energía Atómica
Argentina

(Biblioteca Leo Falicov - CAB)

A mis padres por su amor incondicional hacia mi.

Índice de símbolos

SAR: Synthetic Aperture Radar - radar de apertura sintética
LNA: Low-Noise Amplifier - amplificador de bajo ruido
IF: Intermediate Frequency - frecuencia intermedia
PRI: Pulse Repetition Interval - intervalo de repetición de pulsos
PRF: Pulse Repetition Frequency - frecuencia de repetición de pulsos
CPI: Coherent Processing Interval - intervalo de procesamiento coherente
DEP: Densidad Espectral de Potencia
PPP: Pulse Pair Processing - procesamiento de pares de pulsos
DFT: Discrete Fourier Transform - transformada discreta de Fourier
GMAP: Gaussian Model Adaptive Processing - procesamiento adaptivo usando modelo gaussiano
GMAP-NU: Gaussian Model Adaptive Processing No Uniform - procesamiento adaptivo usando modelo gaussiano no uniforme
FFT: Fast Fourier Transform - transformada rápida de Fourier
CSR: Clutter to Signal Ratio - relación clutter-señal
SNR: Signal to Noise Ratio - relación señal-ruido
CNR: Clutter to Noise Ratio - relación clutter-ruido
IDFT: Inverse Discrete Fourier Transform - transformada discreta inversa de Fourier
IFFT: Inverse Fast Fourier Transform - transformada inversa rápida de Fourier
GMAP-TD: Gaussian Model Adaptive Processing in Time Domain - procesamiento adaptivo usando modelo gaussiano en el dominio del tiempo
SPPP: Staggered Pulse Pair Processing - procesamiento de pares de pulsos escalonados
DA: Dealising Method - método de desambiguación
ASPASS: Adaptive Spectral Processing for Staggered Signals - procesamiento espectral adaptivo para señales escalonadas
PPI: Plan Position Indicator - indicador de posición
GPU: Graphics Processing Units - unidades de procesamiento gráfico
DL: Deep Learning - aprendizaje profundo
DNN: Deep Neural Network - red neuronal profunda
CNN: Convolutional Neural Network - red neuronal convolucional
SGD: Stochastic Gradient Descent - descenso estocástico del gradiente

Índice de contenidos

Índice de símbolos	v
Índice de contenidos	vii
Índice de figuras	xi
Índice de tablas	xv
Resumen	xvii
Abstract	xix
1. Introducción	1
1.1. Antecedentes	4
1.2. Contribuciones originales	8
1.3. Organización de la tesis	11
2. Consideraciones generales	13
2.1. Introducción	13
2.2. Radar meteorológico	14
2.2.1. Señal recibida	16
2.2.2. Ecuación radar meteorológico	20
2.2.3. Muestreo	22
2.3. Momentos espectrales	25
2.3.1. Densidad espectral de potencia (DEP)	26
2.4. Procesamiento Doppler	27
2.4.1. Pulse Pair Processing (PPP)	27
2.4.2. Filtrado de clutter terrestre	28
2.4.3. Gaussian Model Adaptive Processing (GMAP)	29
2.4.4. GMAP in Time Domain (GMAP-TD)	34
2.5. Procesamiento Doppler para modo <i>staggered</i>	37
2.5.1. Staggered PPP	38

2.5.2.	Método de desambiguación de velocidad	40
2.5.3.	GMAP-TD en modo <i>staggered</i>	41
2.6.	Datos de radar meteorológico	42
2.7.	Introducción al machine learning y deep learning	44
2.7.1.	Redes neuronales profundas con alimentación hacia adelante	46
2.7.2.	Entrenamiento de la red neuronal	47
2.7.3.	Redes convolucionales	51
2.8.	Conclusiones	51
3.	Corrección del ancho espectral del clutter y GMAP-NU	53
3.1.	Introducción	53
3.2.	Corrección del ancho espectral del clutter	54
3.2.1.	Formulación del problema	54
3.2.2.	Descripción de la corrección	55
3.2.3.	Resultados	58
3.3.	GMAP no uniforme (GMAP-NU)	59
3.3.1.	Reconstrucción del espectro	61
3.3.2.	Resultados	62
3.4.	Conclusiones	65
4.	Adaptive Spectral Processing for Staggered Signals (ASPASS)	67
4.1.	Introducción	67
4.2.	Método	69
4.2.1.	Interpolación con ceros y estimación de la DEP	70
4.2.2.	Filtrado del clutter terrestre	72
4.2.3.	Estimación de los momentos espectrales	73
4.3.	Simulaciones numéricas	76
4.3.1.	Desempeño en ausencia de clutter terrestre	77
4.3.2.	Desempeño en presencia de clutter terrestre	80
4.3.3.	Complejidad computacional de ASPASS	83
4.3.4.	Desempeño en función de la CSR	84
4.4.	Datos Reales	86
4.5.	Conclusiones	93
5.	Procesamiento Doppler empleando aprendizaje profundo	95
5.1.	Introducción	95
5.2.	Formulación del problema	96
5.2.1.	Descripción del algoritmo	98
5.2.2.	Generación de los datos de entrenamiento y validación	99
5.3.	Estudio de arquitecturas	101

5.3.1.	Entrenamiento y validación de la arquitectura elegida	104
5.4.	Experiencias con datos sintéticos	105
5.4.1.	Desempeño de la DNN en ausencia de clutter terrestre	107
5.4.2.	Desempeño de la DNN en presencia de clutter terrestre	109
5.4.3.	Diferentes SNR	115
5.5.	Procesamiento de datos reales	117
5.6.	Conclusiones	120
6.	Procesamiento Doppler para el modo staggered empleando CNN	125
6.1.	Introducción	125
6.2.	Formulación del problema	126
6.2.1.	Descripción del algoritmo	128
6.2.2.	Generación de los datos de entrenamiento y validación	128
6.3.	Estudio de arquitecturas convolucionales	130
6.3.1.	Entrenamiento y validación de la arquitectura elegida	130
6.4.	Experiencias con datos sintéticos	133
6.4.1.	Desempeño de la CNN en ausencia de clutter terrestre	134
6.4.2.	Desempeño de la CNN en presencia de clutter terrestre	135
6.5.	Procesamiento de datos reales	140
6.6.	Conclusiones	143
7.	Clasificación de la composición de la señal utilizando Redes Neuro- nales	147
7.1.	Introducción	147
7.2.	Formulación del problema	148
7.2.1.	Método	149
7.2.2.	Datos de entrenamiento y validación	151
7.3.	Modo convencional de operación del radar	152
7.3.1.	Estudio de diferentes CNNs	152
7.3.2.	Entrenamiento y validación de la CNN	154
7.3.3.	Experiencia con datos sintéticos	156
7.3.4.	Procesamiento de datos reales	159
7.4.	Modo staggered 2/3	164
7.4.1.	Estudio de diferentes CNNs	164
7.4.2.	Entrenamiento y validación de la CNN elegida	166
7.4.3.	Experiencias con datos sintéticos	167
7.4.4.	Procesamiento de datos reales	169
7.5.	Conclusiones	172
8.	Conclusiones	175

A. Amplitudes de las réplicas	185
Bibliografía	187
Publicaciones asociadas	195
Agradecimientos	197

Índice de figuras

2.1. Esquema del radar	15
2.2. Receptor superheterodino	17
2.3. Volumen de resolución	20
2.4. Transmisión de pulsos	23
2.5. Matriz de datos IQ	24
2.6. Ambigüedad en rango	25
2.7. Ejemplo de DEP	30
2.8. Nivel de ruido	31
2.9. DEP y máscara de clutter	32
2.10. Reconstrucción de la DEP en GMAP	33
2.11. Lógica de decisión para el proceso de optimización de la ventana empleada.	34
2.12. Esquema de procesamiento GMAP-TD	37
2.13. Muestreo <i>staggered</i>	39
2.14. Respuesta en potencia del filtro para la versión <i>staggered 2/3</i> de GMAP-TD con una relación potencia de clutter-potencia de ruido $CNR = 60$ dB, $\sigma_c = 0,28$ m/s.	43
2.15. Red neuronal <i>feedforward</i> densa	47
2.16. Operación de convolución en dos dimensiones.	52
3.1. Máscara de clutter y DEP filtrada sin corrección del ancho del clutter	56
3.2. Máscara de clutter y DEP filtrada con corrección del ancho del clutter	59
3.3. Análisis de errores en la estimación de los momentos espectrales para el algoritmo GMAP con y sin corrección del ancho espectral del clutter	60
3.4. Diagrama en bloques del algoritmo GMAP-NU	61
3.5. Análisis de errores en la estimación de los momentos espectrales para los algoritmos GMAP y GMAP-NU	64
4.1. Muestreo <i>staggered</i>	68
4.2. Diagrama de flujo de ASPASS	71
4.3. Ejemplo de DEP en modo <i>staggered 2/3</i>	72
4.4. Máscara de clutter en ASPASS	72

4.5. Propiedades de la ventana de Kaiser en función del parámetro α	73
4.6. DEP filtrada en ASPASS	74
4.7. DEP reconstruida en ASPASS	76
4.8. Análisis de error de ASPASS sin clutter	78
4.9. Análisis de error de ASPASS sin clutter	79
4.10. Análisis de error en la estimación de potencia	80
4.11. Análisis de error en la estimación de velocidad	81
4.12. Análisis de error en la estimación del ancho del espectro	82
4.13. Tiempo de ejecución y número de iteraciones de ASPASS y GMAP-TD	83
4.14. Análisis de error variando la CSR en ASPASS	85
4.15. PPI de la reflectividad de datos reales	87
4.16. Análisis de un CPI de los datos reales de reflectividad alta usando ASPASS	89
4.17. Análisis de un CPI de los datos reales de reflectividad media usando ASPASS	90
4.18. Análisis de un CPI de los datos reales donde sólo existe fenómeno y ruido.	90
4.19. PPI de la velocidad Doppler media de datos reales	91
4.20. PPI del ancho del espectro de datos reales	92
5.1. Ejemplos de DEPs	97
5.2. Arquitectura general de la red neuronal	98
5.3. Diagrama de flujo usando DNN	99
5.4. Accuracy usando los datos de validación para las 15 estructuras de NN	102
5.5. Tiempos de entrenamiento y predicción para varias estructuras de NN, usando GPU y CPU	103
5.6. Desempeño del entrenamiento y la validación de la DNN	104
5.7. Histogramas de los errores de clases	106
5.8. Análisis de error en la estimación de velocidad Doppler media del fenómeno en ausencia de clutter terrestre	108
5.9. Análisis de error en la estimación del ancho espectral del fenómeno en ausencia de clutter terrestre	109
5.10. Análisis de error en la estimación de \widehat{CSR}_p y en la potencia del clutter para diferentes σ_p	111
5.11. Análisis de error en la estimación de la potencia del fenómeno en presencia de clutter terrestre para diferentes σ_p	111
5.12. Análisis de error en la estimación de la velocidad Doppler media del fenómeno en presencia de clutter terrestre para diferentes σ_p	112
5.13. Análisis de error en la estimación del ancho espectral del fenómeno en presencia de clutter terrestre para diferentes σ_p	113

5.14. Análisis de error en la estimación de la potencia del fenómeno en presencia de clutter terrestre para diferentes valores de CSR	113
5.15. Análisis de error en la estimación de la velocidad Doppler media del fenómeno en presencia de clutter terrestre para diferentes valores de CSR	114
5.16. Análisis de error en la estimación del ancho espectral del fenómeno en presencia de clutter terrestre para diferentes valores de CSR	114
5.17. Análisis de error en la estimación de la potencia del fenómeno en presencia de clutter terrestre para diferentes valores de SNR	115
5.18. Análisis de error de la velocidad Doppler media del fenómeno en presencia de clutter terrestre para diferentes valores de SNR	116
5.19. Análisis de error en la estimación del ancho espectral del fenómeno en presencia de clutter terrestre para diferentes valores de SNR	116
5.20. PPI de la reflectividad	117
5.21. PPI de la velocidad Doppler media utilizando datos reales	118
5.22. PPI del ancho espectral utilizando datos reales	120
6.1. Ejemplos de DEPs en modo <i>staggered 2/3</i>	127
6.2. Arquitectura general de la CNN	128
6.3. Estudio de diferentes redes convolucionales	132
6.4. Desempeño del entrenamiento y la validación de la CNN	132
6.5. Histogramas de los errores de clases	133
6.6. Análisis de error de las estimaciones de la velocidad Doppler media y del ancho espectral del fenómeno en ausencia de clutter terrestre	136
6.7. Análisis de error de las estimaciones de los momentos espectrales del fenómeno en presencia de clutter terrestre	137
6.8. Análisis de error en las estimaciones de los momentos espectrales del fenómeno en función de σ_t	139
6.9. PPI de la reflectividad	141
6.10. PPI de la velocidad Doppler media usando datos reales	142
6.11. PPI del ancho espectral usando datos reales	144
7.1. Ejemplo de DEPs de diferentes composiciones de señal. (a) $CSR = 40$ dB, $v_p = 0,3v_a = 10$ m/s, $\sigma_p = 3,34$ m/s, $SNR = 20$ dB. (b) $CSR = 20$ dB, $v_p = -0,3v_a = -10$ m/s, $\sigma_p = 3,34$ m/s, $SNR = 20$ dB. (c) $CSR \rightarrow -\infty$ dB, $v_p = 0,3v_a = 10$ m/s, $\sigma_p = 3,34$ m/s, $SNR = 20$ dB. (d) $CSR \rightarrow -\infty$ dB, $SNR \rightarrow -\infty$ dB.	150
7.2. Ejemplo de DEPs en la frontera entre dos clases. (a) $CSR = 0$ dB, $v_p = 0,3v_a = 10$ m/s, $\sigma_p = 1,67$ m/s, $SNR = 20$ dB. (b) $CSR = 0$ dB, $v_p = 0,3v_a = 10$ m/s, $\sigma_p = 3,34$ m/s, $SNR = 20$ dB.	150
7.3. Métricas del estudio de las diferentes arquitecturas de CNN	154

7.4. Desempeño del entrenamiento y la validación en el modo convencional. (a) Loss. (b) Accuracy.	155
7.5. Matriz de confusión de la CNN entrenada utilizando los datos de validación.	155
7.6. Accuracy de la arquitectura número 6 en función del número de neuronas de la capa de entrada.	156
7.7. Análisis de error en la clasificación de la clase S + N para el modo convencional	157
7.8. Análisis de error en la clasificación de la clase C + S + N para el modo convencional	158
7.9. Resultados del procesamiento de los datos reales. (a) PPI de la reflectividad. (b) PPI de la velocidad Doppler media. (c) Clasificación utilizando la CNN.	160
7.10. Matriz de confusión de la CNN para $M = 27$	162
7.11. Resultados del procesamiento de los datos reales. (a) PPI de la reflectividad. (b) PPI de la velocidad Doppler media. (c) Clasificación utilizando la CNN.	163
7.12. Métricas del estudio de las diferentes arquitecturas de CNN para modo <i>staggered</i> . (a) Loss. (b) Accuracy. (c) Tiempo de predicción promedio.	165
7.13. Desempeño del entrenamiento y la validación en el modo <i>staggered</i> . (a) Loss. (b) Accuracy.	166
7.14. Matriz de confusión de la CNN entrenada utilizando los datos de validación.	167
7.15. Análisis de error en la clasificación de la clase S + N para el modo <i>staggered</i>	169
7.16. Análisis de error en la clasificación de la clase C + S + N para el modo <i>staggered</i>	170
7.17. Resultados del procesamiento de los datos reales en modo <i>staggered</i> . (a) PPI de la reflectividad. (b) PPI de la velocidad Doppler media. (c) Clasificación utilizando la CNN.	171

Índice de tablas

3.1. Ajuste gaussiano de las ventanas Hamming y Blackman.	58
3.2. Parámetros para la simulación.	63
4.1. Parámetros para la simulación.	77
5.1. Diferentes arquitecturas de redes neuronales totalmente conectadas. . .	101
5.2. Parámetros para la simulación.	107
6.1. Arquitecturas convolucionales	131
6.2. Parámetros para la simulación.	134
7.1. Parámetros para la simulación.	149
7.2. Diferentes arquitecturas de CNN estudiadas. Modo convencional.	153
7.3. Diferentes arquitecturas de CNN estudiadas. Modo <i>staggered</i>	165
7.4. Parámetros para la simulación.	168

Resumen

El radar meteorológico es un sistema activo de sensado remoto que se utiliza para realizar alertas meteorológicas de corto plazo, contribuyendo a la prevención de pérdidas de índoles humanas y económicas. Su principio de funcionamiento consiste en transmitir energía en forma de ondas electromagnéticas y recibir parte de la energía reflejada por los fenómenos meteorológicos de interés. Dada la naturaleza aleatoria de la señal recibida, se utilizan técnicas de procesamiento estadístico para obtener información útil de los fenómenos meteorológicos bajo estudio. En particular, en los radares Doppler meteorológicos los parámetros de interés lo constituyen los tres momentos de menor orden del espectro de la señal: la potencia, la velocidad Doppler media, y el ancho espectral.

Una de las dificultades a tener en cuenta en los radares es que la señal de interés suele encontrarse obscurecida por reflexiones no deseadas, a las cuales se las denomina *clutter*. Existen diferentes fuentes de *clutter*, en el caso del radar meteorológico el *clutter* terrestre, debido a reflexiones producidas sobre el suelo y todo lo que allí se encuentra, posee un impacto significativo sobre las estimaciones de los parámetros de interés, por lo que sus efectos se deben eliminar o reducir. Por otro lado, como en todo radar pulsado, el radar meteorológico presenta los problemas de ambigüedades en la determinación del rango y la velocidad Doppler. En el modo de operación convencional, es decir cuando se utiliza un único valor para el intervalo de repetición de pulsos (PRI), aumentar el rango no ambiguo implica disminuir la velocidad Doppler máxima no ambigua y viceversa. La solución más utilizada para lidiar con esta relación de compromiso es alternar el PRI, en general, entre dos valores, a lo que se denomina modo de operación *staggered*. En esta tesis se abordan los problemas del filtrado de *clutter* terrestre, la estimación de los momentos espectrales y la clasificación de la composición de la señal recibida para el radar meteorológico Doppler. Se presentan soluciones tanto para el modo convencional de operación del radar, como para el modo de operación *staggered*.

Inicialmente, se propone una corrección para el ancho espectral del *clutter* observado con el objetivo de mejorar el filtrado del mismo con aquellos algoritmos que realizan el procesamiento en el dominio del espectro. Posteriormente se introduce el algoritmo Gaussian Model Adaptive Processing No Uniform (GMAP-NU) como solución al filtrado de *clutter* terrestre y estimación de momentos espectrales de señales adquiridas en el

modo de operación *staggered*. Se muestra que el algoritmo presenta un buen desempeño, comparable al del algoritmo Gaussian Model Adaptive Processing (GMAP) con PRI uniforme. Sin embargo, posee una restricción propia sobre la velocidad Doppler máxima que impide explotar el intervalo Doppler no ambiguo que ofrece el modo *staggered* y limita su uso desde un punto de vista práctico.

Luego, se desarrolla el algoritmo Adaptive Spectral Processing for Staggered Signals (ASPASS), también para el filtrado de *clutter* terrestre y estimación de los momentos espectrales del fenómeno meteorológico. El mismo se basa en ideas análogas a las de GMAP pero aplicadas a secuencias adquiridas con el modo de operación *staggered*. Se estudia su desempeño empleando tanto simulaciones numéricas como datos reales adquiridos con el radar argentino RMA-12 situado en el aeropuerto de la ciudad de San Carlos de Bariloche. Los resultados son comparables a los de GMAP-TD, e inclusive mejores, en cuanto a errores relativos y tiempos de cómputo.

Por otro lado, se introduce un enfoque diferente para el procesamiento de la señal radar meteorológico que consiste en emplear herramientas de *machine learning*. En primer lugar, se utilizan redes neuronales artificiales para la estimación de los momentos espectrales tanto en presencia como en ausencia de contribuciones de *clutter* terrestre en la señal recibida. Se emplea la densidad espectral de potencia (DEP) como entrada a las redes y éstas últimas son entrenadas utilizando datos sintéticos, lo que permite crear bases de datos contemplando una gran diversidad de configuraciones meteorológicas. Este enfoque se aplica a los modos de operación convencional y *staggered*. En ambos casos, se estudia el desempeño de la respectiva red por medio de simulaciones numéricas y mediciones reales adquiridas con el radar RMA-12. En general, el desempeño es comparable al de algoritmos ampliamente utilizados en la comunidad para resolver este tipo de problemas, lo que pone de manifiesto la versatilidad del método propuesto teniendo en cuenta que el entrenamiento se realiza empleando datos sintéticos.

Finalmente, se emplean redes neuronales convolucionales en el problema de clasificación de la composición de la señal recibida, con el objetivo de detectar la presencia de *clutter* terrestre. Nuevamente, se toma la DEP como entrada a las redes, las mismas son entrenadas utilizando datos sintéticos y el clasificador se aplica para ambos modos de operación del radar. Para cada modo, las redes entrenadas son evaluadas mediante diferentes experimentos por medio de simulaciones numéricas y su funcionamiento es validado a través de mediciones reales adquiridas por los radares RMA-11 y RMA-12. Los resultados muestran que las redes entrenadas poseen tasas de acierto mayor al 90 % en la mayor parte de las situaciones estudiadas, y que su desempeño se degrada en configuraciones meteorológicas puntuales, en las cuales es difícil distinguir la contribución de cada componente sobre la DEP resultante.

Palabras clave: RADAR METEOROLÓGICO, CLUTTER TERRESTRE, MOMENTOS ESPECTRALES, PROCESAMIENTO DOPPLER.

Abstract

A weather radar is a remote sensing active device used in short term (nowcasting) meteorological alert systems, allowing the prevention of human and economic losses. Its operating principle consists in transmitting energy through electromagnetic waves and receiving part of the energy reflected by the meteorological objects of interest. Due to the random nature of the received signal, statistical processing techniques are used to obtain useful information of the weather phenomenon under study. In Doppler weather radars, the parameters of interest are the first three moments of the signal spectrum.

One of the difficulties to consider in radars is that the signal of interest is usually obscured by unwanted reflections, known as clutter. There are different clutter sources. In the case of the weather radar, the ground clutter, due to reflections produced by the ground and everything on it, has a huge impact on the estimation of the parameters of interest, therefore its effect must be eliminated or reduced. Also, as in every pulsed radar, the weather radar presents range and Doppler ambiguity problems. In the conventional operating mode, when only one value for the pulse repetition interval (PRI) is used, increasing the maximum unambiguous range implies decreasing the maximum Doppler velocity, and vice versa. The most used solution to deal with this trade-off is to use different PRI values, alternating between two values, denominated *staggered* operating mode.

In this thesis, the ground clutter filtering problem, the spectral moments estimation and the received signal composition classification for the Doppler weather radar are addressed. Solutions are presented for both the conventional and the *staggered* radar operating modes.

The first result presented is a correction for ground clutter spectral width estimation, which aims at improving the filtering stage in all those algorithms which use the spectral domain to process the signal. Afterwards, a solution to ground clutter filtering and spectral moments estimation for signals acquired in the *staggered* operating mode is introduced, named GMAP-NU. It is shown that the algorithm presents a performance similar to GMAP for uniform PRI. The main drawback of this algorithm is a restriction in the maximum velocity which prevents it to exploit the entire unambiguous Doppler

interval that the *staggered* mode allows, thus limiting its use for real implementations. Next, a novel ground clutter filtering and spectral moments estimation algorithm is presented, named ASPASS. It is based on the same principle than GMAP but applied to *staggered* sequences. ASPASS performance is studied both by means of numerical simulations and also using real data acquired with the RMA-12 weather radar, located in San Carlos de Bariloche airport. The results are akin to those obtained with GMAP-TD, and outperform this method in terms of relative errors and computing times.

Also, a different approach for weather radar signal processing is presented, which relies on machine learning tools. Neural networks are used for weather spectral moments estimation both in the presence and absence of ground clutter. The power spectral density (PSD) is used to feed the neural networks. These are trained using synthetic data, which allows for the creation of huge databases contemplating a great diversity of meteorological situations. This approach is applied to the conventional and the staggered operating modes. In both cases, the neural network performance is studied by means of numerical simulations and real data acquired with the RMA-12 weather radar. In general, the performance is comparable with other widely used algorithms to solve this kind of problems, which reveals the versatility of the proposed method having in mind that the training is performed by means of synthetic data.

Finally, convolutional neural networks are used to solve a signal classification problem, with the objective of detecting the presence of ground clutter. Again, the PSD is used to feed neural networks, which are trained using synthetic data and the method is, again, applied to both radar operating modes. For every mode, trained neural networks are tested by means of numerical simulations and their behaviour is validated using real data from RMA-11 and RMA-12 radars. Results show that the trained networks have hit rates greater than 90 % in the majority of the considered situations. The algorithms performance degrades for very particular weather situations, in which it is hard to distinguish the contribution of each component to the resultant PSD.

Keywords: WEATHER RADAR, GROUND CLUTTER, SPECTRAL MOMENTS, DOPPLER PROCESSING

Capítulo 1

Introducción

“En el fondo, los científicos somos gente con suerte: podemos jugar a lo que queramos durante toda la vida.”

— LEE SMOLIN

En todas las ramas del conocimiento, existen y existieron personas que han realizado aportes relevantes para el desarrollo de la misma. Tal es el caso de James Clerk Maxwell en temas de electromagnetismo. De hecho, el término anterior se deriva de sus estudios pioneros por tratar de unificar las teorías eléctrica y magnética existentes en la primera mitad del siglo XIX. Su gran contribución fue reunir, a inicios de la segunda mitad del siglo XIX, en un conjunto de ecuaciones que llevan su nombre, la descripción de los fenómenos electromagnéticos [1]. A partir de las mismas, se deduce la existencia de ondas electromagnéticas que se propagan, dependiendo del medio material, a la velocidad de la luz en dicho medio. De esta forma Maxwell identificó la luz como una onda electromagnética, unificando la óptica con el electromagnetismo. No fue hasta el período comprendido entre los años 1886-1889 en el que Heinrich Hertz demostró experimentalmente la hipótesis anteriormente expuesta por Maxwell, respecto de que las ondas electromagnéticas son idénticas a las ópticas, excepto por la longitud de onda.

El trabajo de Hertz fue extendido por Christian Hulsmeier a principios del siglo XX, quien construyó en 1904 un dispositivo (lo que se conoce hoy en día como radar monoestático pulsado) para detectar embarcaciones y prevenir choques entre ellas [2]. A pesar del éxito que obtuvo, los intereses de Christian no estaban alineados con las aplicaciones que se le dió a su dispositivo en aquella época, lo cual hizo que su invención y demostraciones fueran olvidadas. Lamentablemente, la ciencia detrás del radar tuvo que ser reinventada varias veces hasta que el mismo se convirtió en una realidad operativa.

El término *radar* (en inglés, *radio detection and ranging*) se convirtió a principios de 1940 en el acrónimo oficial de los equipos que utilizan radio frecuencias para la detección y conocimiento de la distancia de los objetos [3]. El acrónimo fue adoptado

en 1943 por los Aliados durante la Segunda Guerra Mundial y posteriormente recibió aceptación internacional. El término radio se aplica a todas las ondas electromagnéticas cuyas frecuencias están comprendidas aproximadamente entre 1kHz y 500 GHz. Los radares pulsados convencionales son sistemas activos que operan transmitiendo energía en forma de ondas electromagnéticas y recibiendo las señales reflejadas por la región y los objetos de interés iluminados [2]. Si estos últimos presentan un tamaño tal que entran dentro del volumen de resolución del radar, se consideran reflectores puntuales, tal es el caso de aviones, helicópteros, etc. En general, en este tipo de aplicaciones se emplean técnicas de procesamiento de señales para extraer información del objetivo. La función básica del procesamiento consiste en la detección de la presencia de contribuciones de uno o más objetivos en la señal recibida [4]. Una vez detectados, se puede estimar: la distancia al objetivo, que es proporcional al retardo de tiempo en que la señal recibida cruzó el umbral de detección con respecto al instante en que el pulso fue transmitido; el ángulo relativo a la dirección de apuntamiento de la antena; y la velocidad radial, midiendo el desplazamiento en función del tiempo [2].

Por su parte, el principio de funcionamiento de los radares meteorológicos es análogo al descrito, aunque el problema es ligeramente diferente. Los blancos en esta ocasión son fenómenos atmosféricos que reflejan la energía radiada, en general asociada a hidrometeoros [5]. Estos fenómenos están conformados por zonas de gran extensión comparadas con el tamaño del volumen de resolución del radar, en contraposición a los *puntuales*.

Si bien los primeros desarrollos de radar pulsado aplicado a observaciones meteorológicas surgieron en la década de 1950 [3], desde el punto de vista de radares operativos existen dos saltos tecnológicos muy importantes. El primero es el *radar meteorológico Doppler*, que permite obtener los momentos espectrales de la señal recibida en la dimensión *tiempo lento* [6]. Frecuentemente, se modela la densidad espectral de potencia (DEP) de los fenómenos atmosféricos como una función gaussiana [7], y mediante técnicas de procesamiento Doppler se estiman sus momentos. El de orden cero, o la potencia, está relacionado con el tipo de fenómeno y con la tasa de precipitación dentro del volumen de resolución; el de primer orden o la velocidad Doppler media, se encuentra vinculada con la velocidad del viento; y el de segundo orden o ancho espectral, es una medida de la dispersión de la velocidad, debida, principalmente, a los efectos de cizalladura del viento, la turbulencia dentro del volumen y el movimiento de la antena del radar [3].

El segundo hito tecnológico lo conformó el *radar meteorológico polarimétrico*, que además de las capacidades Doppler incorpora la posibilidad de transmitir y recibir las ondas electromagnéticas con más de una polarización. Dado que el estado de polarización de las ondas electromagnéticas recibidas es sensible a la forma física y a las propiedades dieléctricas de los hidrometeoros, se puede identificar el tipo de fenómeno

meteorológico y mejorar la estimación de la tasa de precipitación. Para ello, se estudian diferentes productos polarimétricos [8] como son: la reflectividad diferencial, la fase diferencia, el coeficiente de correlación copolar, etc.

En Argentina, en el año 2011 se implementó el Sistema Nacional de Radares Meteorológicos (SINARAME), con el objetivo principal de contar con una red de radares meteorológicos utilizando un sistema de centralización de la información en tiempo real, el cual es operado por el Servicio Meteorológico Nacional. En este contexto, la empresa INVAP fue la responsable de la fabricación y puesta en funcionamiento de 12 radares polarimétricos, en banda C, distribuidos a lo largo del país [9, 10]. Se prevé para un futuro extender la red a un total de 30 radares con estas características, capaces de proveer una cobertura completa del territorio nacional.

Una de las dificultades a tener en cuenta en los sistemas radar es que la señal de interés suele encontrarse obscurecida por reflexiones no deseadas, a las cuales se las denomina clutter [11]. El mismo es considerado una fuente de interferencia y perturbaciones aleatorias cuyos efectos se deben eliminar o reducir, debido a que sesgan las estimaciones de los parámetros de interés [12]. Si bien el radar meteorológico posee apuntamiento hacia el cielo, parte del lóbulo de su antena recibe reflexiones del terreno, que por lo general poseen una intensidad considerablemente mayor a las atmosféricas. Estas reflexiones que se producen sobre el suelo, y todo lo que allí se encuentra, tal como árboles, edificios, montañas, etc., contaminan y enmascaran los ecos provenientes de los fenómenos atmosféricos que se desean observar. A este tipo de interferencia se le denomina *clutter terrestre*, y es uno de los factores limitantes más importantes para la estimación de los momentos espectrales de los fenómenos [13, 14].

En su configuración estándar, los radares pulsados transmiten una serie periódica de pulsos. El período de tiempo entre pulsos se conoce como intervalo de repetición de pulsos (en inglés, Pulse Repetition Interval, PRI) y su inversa es la frecuencia de repetición de pulsos (en inglés, Pulse Repetition Frequency, PRF). En la porción de tiempo comprendida entre pulsos, la señal recibida es muestreada, por ende cada una de estas muestras se corresponde a una distancia de acuerdo con el retardo respecto al instante en el que el pulso fue transmitido. Por este motivo, para cada distancia o *celda de rango* se cuentan con tantas muestras como pulsos transmitidos [6]. En este esquema de funcionamiento la distancia máxima que se puede resolver sin ambigüedad resulta inversamente proporcional a la PRF, mientras que la velocidad Doppler media máxima del objetivo que se puede medir sin ambigüedad es proporcional a la PRF. Esto conlleva a una relación de compromiso entre estos dos parámetros de interés [15].

Una de las estrategias comúnmente utilizadas para cumplir con el requisito de distancia máxima sin deteriorar la velocidad máxima no ambigua consiste en variar la PRF entre pulsos sucesivos, lo que se conoce como modo de funcionamiento de PRF alternadas o modo *staggered* [2]. Cuando el radar opera de esta forma los datos genera-

dos para cada celda de rango presentan la particularidad de encontrarse muestreados de manera no uniforme. Esto implica que las técnicas estándar de estimación de momentos espectrales o detectar y filtrar el clutter terrestre no sean directamente aplicables [15]. A pesar de que existen diferentes combinaciones de PRIs [16], el sistema con dos PRIs es el más usado, en el cual se alterna entre T_1 y T_2 , siendo $T_1 < T_2$. La velocidad ambigua para este esquema depende inversamente de la diferencia $T_u = T_2 - T_1$ y se demuestra que a medida que la relación $k = T_1/T_2$ tiende a uno, los errores de estimación aumentan [17]. Por esta razón, la elección $T_1 = 2T_u$ y $T_2 = 3T_u$ es comúnmente utilizada como solución a la relación de compromisos anterior. Este modo de operación se conoce como *staggered 2/3*.

1.1. Antecedentes

Los radares meteorológicos se han establecido como una herramienta fundamental para realizar predicciones del tiempo a corto y muy corto plazo. Los pronosticadores se basan en la información que los radares brindan para realizar pronósticos y alertas tempranas de fenómenos catastróficos como pueden ser la caída de granizos, vientos intensos, lluvias intensas, entre otros, evitando de esta forma pérdidas de índole humana y económicas.

En las aplicaciones de radar meteorológico Doppler se emplean técnicas de procesamiento con el objetivo de determinar los momentos espectrales del fenómeno. Existen diferentes enfoques para atacar dicho problema. Para el modo convencional de operación, uno de los más simples es usar *Procesamiento Espectral* (en inglés, Spectral Processing, SP), que consiste en evaluar los momentos espectrales por definición, una vez que el espectro es estimado. El uso de la Transformada rápida de Fourier (en inglés, Fast Fourier Transform, FFT) lo hace atractivo por su bajo costo computacional, sin embargo, está comprobado que el mismo presenta problemas para las situaciones en las que existe efecto de replicado (en inglés, *aliasing*) en el espectro, reportando valores sesgados en las estimaciones de los momentos de primer y segundo orden [3, 18]. Aunque esto último se puede corregir con procesamiento extra, por otro lado, también se ha comprobado que SP presenta sesgo en las estimaciones debido a la longitud finita de las señales a procesar [19], principalmente para situaciones de baja relación potencia de señal a potencia de ruido (SNR).

El algoritmo *Pulse Pair Processing* (PPP) es uno de los métodos de estimación de momentos espectrales más usados en la actualidad. Los momentos se calculan a partir de estimados de la autocorrelación de la señal radar, $\hat{R}(kT_u)$ $k \in \mathbb{Z}$, siendo T_u el intervalo de repetición de pulso. El momento de orden cero es igual a $\hat{R}(0)$ menos la potencia del ruido, el momento de primer orden depende de forma proporcional a la fase de $\hat{R}(T_u)$ y el momento de segundo orden depende de forma no lineal del

cociente entre $\hat{R}(T_u)$ y el momento de orden cero. El algoritmo PPP también es eficiente computacionalmente hablando, pero sus estimaciones se degradan para valores de SNR menores a 10 dB, y cuando el ancho espectral del fenómeno meteorológico aumenta [20].

Para el estudio de la velocidad Doppler media, existen alternativas que combinan estimaciones de la autocorrelación en diferentes retardos o *lags* con el objetivo de mejorar el desempeño de PPP. Dos alternativas son los estimadores *Poly-PPP* y *Periodogram Maximization* [19]. A diferencia de PPP, estos métodos utilizan toda la información contenida en la autocorrelación. Sin embargo, ninguno alcanza un desempeño mejor que el de PPP, debido a que las estimaciones de la autocorrelación a mayores *lags* sufren de incrementos en los errores.

Por otro lado, métodos basados en criterios de estimación óptima como el de *máxima verosimilitud* [21] pueden alcanzar muy buen desempeño, pero su alto costo computacional los excluye de ser implementados en aplicaciones a tiempo real. También existen técnicas adaptativas para la estimación de los momentos espectrales. En [22] se modela la señal radar como una serie compleja autoregresiva de primer orden y se deduce un filtro adaptivo en términos de la probabilidad máxima a posteriori para realizar las estimaciones. El desempeño del método se degrada significativamente cuando el número de muestras es pequeño, haciendo que el mismo sea poco recomendable para aplicaciones reales en las cuales el número de muestras suele ser del orden de 64 o menor.

En general, la señal que retorna al radar puede ser modelada como la suma de las contribuciones de los reflectores meteorológicos, clutter terrestre, para bajos ángulos de elevación, y ruido. La presencia de clutter terrestre en la señal meteorológica produce estimaciones sesgadas de los momentos espectrales utilizando los algoritmos antes mencionados. Por esta razón su eliminación es una tarea crucial para mejorar la calidad de los productos del radar. Debido a que el clutter terrestre está mayormente estático, posee su espectro concentrado alrededor de la frecuencia cero, por lo tanto el método más básico para tratar con él consiste en aplicar un filtro pasaaltos fijo [23]. La desventaja de este método radica en que si el espectro del fenómeno se encuentra cerca del origen también se filtran sus componentes, lo cual conlleva a estimaciones sesgadas de los momentos espectrales. Para solucionar este problema se han propuestos diversos algoritmos que usan estrategias adaptativas para reconstruir las componentes espectrales del fenómeno eliminadas en el proceso de filtrado del clutter [14, 24–26].

Uno de los algoritmos adaptativos más utilizado es *Gaussian Model Adaptive Processing* (GMAP) [24]. El algoritmo GMAP opera en el dominio espectral. Posee una etapa de filtrado de clutter mediante una máscara, seguido de una etapa de reconstrucción de las componentes espectrales del fenómeno eliminadas y, finalmente, luego de aplicar la transformación correspondiente, se estiman de forma iterativa los momentos espectrales utilizando PPP. Tanto para el filtrado de clutter, como en la reconstruc-

ción espectral utiliza el modelo gaussiano para las DEPs del clutter terrestre y del fenómeno meteorológico. Dado que su implementación transcurre, principalmente, en el dominio espectral, es un método eficiente desde el punto de vista computacional, ya que involucra operaciones matemáticas como la Transformada Discreta de Fourier (DFT) y su transformada inversa. Como desventaja, al igual que todos los métodos de filtrado espectrales, es que el efecto de derrame (en inglés, leakage) degrada significativamente su desempeño, como consecuencia del pequeño número de muestras que poseen la secuencias que se procesan, lo cual impacta negativamente en el resultado de las estimaciones.

Una variante a GMAP es el método adaptivo *Gaussian Model Adaptive Processing in Time Domain* (GMAP-TD) [25]. Como su nombre indica, este algoritmo mantiene el enfoque de GMAP, pero opera en el dominio del tiempo, es decir sobre la autorrelación de la señal. Aplica un filtro a la autocorrelación de la señal para suprimir el clutter terrestre. Posteriormente, mediante un proceso iterativo recupera las componentes del fenómeno filtradas empleando el modelo gaussiano para su autocorrelación y estima los momentos espectrales utilizando PPP. Una de sus ventajas es que no presenta el problema del leakage mencionado en GMAP, sin embargo, su carga computacional es alta debido a que involucra operaciones con matrices tales como inversiones y multiplicaciones.

En [26] se presenta el método *Clutter Environment Analysis using Adaptive Processing* (CLEAN-AP). Este algoritmo utiliza una nueva magnitud introducida en [27] como una extensión de la DEP, denominada autocorrelación de la densidad espectral (en inglés, autocorrelation spectral density, ASD). A diferencia de la DEP, la ASD incluye información de fase, lo cual provee una mejor herramienta para la identificación de señales con espectros angostos, como es el caso del clutter terrestre. Después de identificar y filtrar el clutter, CLEAN-AP estima los momentos espectrales usando PPP a partir de estimados de la autocorrelación provenientes de la ASD.

Además de los métodos adaptivos antes mencionados, existen algoritmos que utilizan criterios de optimización como el de *máxima verosimilitud* para realizar las estimaciones de los momentos espectrales en presencia de clutter terrestre. Este es el caso del algoritmo *Parametric Time Domain Method* (PTDM) [28], donde al igual que en GMAP se supone que la señal es la suma de contribuciones independientes del fenómeno, clutter terrestre (ambos con DEP de forma Gaussiana) y ruido blanco, y al mismo tiempo la densidad de probabilidad de la señal es también Gaussiana. Si bien los resultados que se obtienen son buenos, su costo computacional es muy alto debido a que al no poseer solución cerrada, se debe resolver numéricamente un problema de optimización de seis variables, haciéndolo inviable en aplicaciones en tiempo real.

Para el modo de operación *staggered*, debido al muestreo no uniforme resultante en la dirección de tiempo lento, el problema a resolver presenta un grado mayor de

dificultad que para el modo convencional. A pesar de esto último, se han desarrollado diversas técnicas que permiten obtener los momentos espectrales de los fenómenos meteorológicos. Algunas son extensiones de los métodos mencionados anteriormente, como es el caso de Staggered PPP (SPPP) [17], en el cual la estimación de velocidad Doppler media es proporcional a la diferencia de los argumentos de $\hat{R}(T_1)$ y $\hat{R}(T_2)$ y para el ancho espectral existen diversas alternativas que dependen de los estimados $\hat{R}(0)$, $\hat{R}(T_1)$ y $\hat{R}(T_2)$, respectivamente [17]. Si bien el método es eficiente desde el punto de vista computacional, para la estimación de la velocidad presenta valores altos de error debido a que la misma depende de la resta de dos estimados.

Una alternativa a SPPP para la estimación de velocidad Doppler media es el método *Dealising* (DA) [29], el cual calcula dos valores de velocidad, \hat{v}_1 a partir de $\hat{R}(T_1)$ y \hat{v}_2 a partir de $\hat{R}(T_2)$, para luego desambiguar los valores obtenidos y estimar el valor correcto de velocidad. DA es ligeramente más complejo que SPPP y presenta un desempeño significativamente mejor que éste último para un amplio rango de anchos espectrales.

Otras técnicas de estimación de momentos espectrales provienen de enfoques diferentes. Tal es el caso del método *Multi-Pulse processing* MPP [30], donde se mejora la estimación de la velocidad Doppler media mediante la búsqueda de ceros de un funcional que se define a partir de la autocorrelación de la señal en múltiples lags. Los resultados obtenidos demuestran mejoras significativas respecto de DA para escenarios de valores bajos de SNR. Otra de las ventajas del método es que puede ser aplicado tanto a señales adquiridas en el modo convencional como en el modo *staggered*. A pesar de la mejora en el desempeño, presenta la desventaja de depender de una estimación previa de la velocidad, realizada utilizando otro algoritmo.

Al igual que para el modo de operación convencional, en el modo de operación *staggered* también es necesario filtrar el clutter terrestre previo a la estimación de los momentos espectrales. La evolución de las estrategias de filtrado de clutter también pasó por un proceso análogo al descrito para PRI uniforme, inicialmente se emplearon filtros fijos y luego surgieron las versiones adaptativas. Dentro de este último grupo, muchos de los algoritmos son extensiones de los mencionados para el modo de operación convencional, como ser GMAP-TD [25], PTDM [31] y CLEAN-UP [32, 33].

Por su parte, en [34] se introduce un filtro de clutter y una metodología denominada *deconvolución de la magnitud* (en inglés, *magnitude deconvolution*, MD), para reconstruir el espectro de la secuencia muestreada de forma no uniforme. A partir del espectro reconstruido se estiman los valores de la autocorrelación y mediante PPP se obtienen los momentos espectrales. Cabe mencionar que si la señal no presenta clutter terrestre, MD puede ser aplicado junto con PPP para obtener los momentos espectrales. En el trabajo original, cuando el clutter contamina la señal, al aplicar el filtro de clutter, no existía una etapa de reconstrucción de las componentes espectrales del fenómeno eliminadas, lo cual implicaba la existencia de un pequeño sesgo en las estimaciones de

velocidad y de ancho espectral. Razón por la cual en [29] el algoritmo fue mejorado para que incluyera la reconstrucción de las muestras eliminadas del fenómeno y de esta forma disminuir el sesgo en las estimaciones.

La mayoría de los métodos de filtrado de clutter antes mencionados (GMAP, GMAP-TD, PTDM) requieren de una etapa previa de detección del mismo para no incurrir en el filtrado innecesario de la señal radar. En este sentido, existen diferentes alternativas para resolver el problema de detección de clutter. Una de ellas es el método *clutter mitigation decision* (CMD) [14]. CMD utiliza como entradas la información de un parámetro de fase y de cuatro parámetros espaciales, y a partir de un algoritmo de lógica difusa clasifica si en la señal se encuentra presente clutter o fenómeno meteorológico. CMD presenta buen desempeño identificando clutter en propagación anómala y en propagación normal, pero su desempeño puede ser mejorado si se emplea información polarimétrica [14].

En [35] los autores utilizan las propiedades estadísticas del clutter terrestre y del fenómeno para detectar la presencia del primero. Diseñan un clasificador Bayesiano simple [36] (SBC por sus siglas en inglés) tomando como entradas del clasificador la media y la covarianza de la señal recibida por el radar. Además, se basan en las diferencias polarimétricas que existen entre los ecos del fenómeno meteorológico y del clutter. En [37] se desarrolla el algoritmo dual-polarization and dual-scan (DPDS) para la detección de clutter en las observaciones meteorológicas. Como su nombre indica, el mismo utiliza dos barridos completos (360°) y ambas polarizaciones (horizontal y vertical) para estimar la autocorrelación y la correlación cruzada (entre los dos barridos, y entre los canales horizontal y vertical). Posteriormente, se define un clasificador Bayesiano para realizar la clasificación. El método fue probado en el radar WSR-88D obteniéndose resultados satisfactorios. Por su parte, en [38] se desarrolla un nuevo método de detección de clutter y de fenómeno, basado en el discriminante *fluctuación del índice de fase* (PFI por sus siglas en inglés). En este caso, también se hace uso de las características distintivas de la señal constituida sólo por contribuciones del fenómeno meteorológico, con respecto a las que posee ante la presencia de clutter terrestre. El PFI se calcula para ambos canales de recepción, con polarizaciones horizontal y vertical, y se aplica clasificación Bayesiana para la toma de decisiones.

1.2. Contribuciones originales

El objetivo general del presente trabajo consiste en desarrollar modelos y algoritmos de procesamiento estadístico de las señales adquiridas por radares meteorológicos. En ese marco las principales contribuciones de esta tesis, asociadas a los objetivos específicos, abordan los problemas de filtrado de clutter terrestre y de estimación de los momentos espectrales del fenómeno meteorológico considerando tanto el modo de ope-

ración convencional como el modo de operación *staggered*, y por último la clasificación de la composición de la señal radar meteorológico.

En primer lugar, se propuso una corrección en la estimación del ancho espectral del clutter terrestre [39], con el objetivo de construir de forma adecuada la máscara con la que se realiza el filtrado en una serie de algoritmos adaptivos que operan en el dominio del espectro. El método corrige el ancho espectral nominal que se espera que posea el espectro del clutter teniendo en cuenta el ensanchamiento producido por la ventana utilizada durante el procesamiento.

En cuanto al filtrado de clutter terrestre y la estimación de momentos espectrales del fenómeno meteorológico se hicieron varias contribuciones. La primera de ellas es un algoritmo al que se ha denominado *Gaussian Model Adaptive Processing No Uniform* (GMAP-NU) [40], que procesa señales adquiridas en el modo de operación *staggered*. El mismo combina dos métodos preexistentes, por un lado un algoritmo que permite reconstruir el espectro de la señal en una grilla uniforme a partir de muestras con espaciado temporal no uniforme, que luego es utilizado para generar la señal de entrada para el algoritmo GMAP. Mediante simulaciones numéricas de tipo Monte Carlo se estudió el desempeño de GMAP-NU y se lo comparó con el de GMAP bajo las mismas condiciones de simulación, pero con señales adquiridas con espaciado uniforme. Si bien GMAP-NU presenta una restricción en la velocidad máxima no ambigua que puede resolver, lo cual limita su utilización en la práctica, significó un paso importante como punto de partida para el abordaje del problema de procesamiento involucrado en el modo de operación *staggered*.

En segundo lugar, se diseñó el algoritmo *Adaptive Spectral Processing for Staggered Signals* ASPASS [41], también como una solución al filtrado de clutter terrestre y la estimación de los momentos espectrales para el modo de operación *staggered*. ASPASS surge inspirado en las ideas del algoritmo GMAP, se lo puede considerar una extensión del mismo para señales adquiridas en el modo de operación *staggered* del radar. A diferencia de GMAP-NU explota el rango máximo de velocidades no ambiguas que admite el modo de operación *staggered* y al funcionar en el dominio del espectro conserva el bajo costo computacional que presenta GMAP. Para validar el desempeño de ASPASS se emplearon simulaciones numéricas de tipo Monte Carlo y mediciones reales adquiridas con el radar argentino RMA-12 emplazado en el aeropuerto de la ciudad de San Carlos de Bariloche. Además, se comparó su desempeño con el de otros algoritmos como: DA y SPPP para la estimación de velocidad Doppler media y del ancho espectral, respectivamente, en escenarios sin la presencia de clutter terrestre; y con GMAP-TD en escenarios donde el clutter terrestre contamina la señal. Para ambos escenarios, los resultados obtenidos sugieren que ASPASS posee buen desempeño, el mismo comparable con el de los otros algoritmos.

Por otro lado, se introdujo una nueva metodología utilizando técnicas de machine

learning para procesar la señal de radar meteorológico. En particular, como modelo de machine learning se emplearon redes neuronales (en inglés, neural networks, NN) artificiales a las que se ingresa con una estimación de la DEP de las señales adquiridas, explotando la estructura que presenta la DEP de las señales meteorológicas para estimar los momentos espectrales del fenómeno. Una característica interesante consiste en que las redes neuronales son entrenadas utilizando datos sintéticos y aún así presenta un buen desempeño, comparable al de algoritmos clásicos que se emplean para resolver el mismo problema. Esto permite la creación de grandes bases de datos bien etiquetadas contemplando diversas situaciones meteorológicas.

En una primera instancia, este enfoque fue aplicado al modo convencional de operación del radar [42]. Se diseñó una NN profunda (DNN, por sus siglas en inglés) con tres ramas, donde cada una presenta una estructura densa y, a partir de un esquema de clasificación, se utilizan para la estimación de los siguientes parámetros: relación potencia de clutter a potencia de señal, CSR ; velocidad Doppler media, v_p ; y ancho espectral, σ_p ; respectivamente. Para cada rama se elige un determinado número de clases o neuronas de salida, donde cada clase se mapea a un valor de CSR , v_p y σ_p , respectivamente. Una vez elegida y entrenada la DNN, se estudió su desempeño utilizando simulaciones numéricas de tipo Monte Carlo y datos reales adquiridos con el radar RMA-12. Para las simulaciones numéricas se tomó el sesgo y la desviación estándar de los estimados como métricas. Además, se comparó el desempeño de la DNN con el de PPP para escenarios sin la presencia de clutter terrestre y con GMAP para escenarios donde el clutter contamina la señal.

La técnica de machine learning también se aplicó al problema de estimación de momentos espectrales en el modo de operación *staggered*. El procedimiento seguido es análogo al del modo de operación convencional pero teniendo en cuenta las diferencias entre ambos problemas. Por un lado, la señal *staggered* se interpola con ceros para generar una secuencia con espaciado temporal uniforme a partir de la señal adquirida a partir del muestreo no uniforme, lo cual conlleva a la aparición de réplicas en el espectro, tanto para el clutter como para el fenómeno. Por otro lado, para las ramas de la NN se utilizaron redes convolucionales (CNN, por sus siglas en inglés) en una dimensión. El desempeño de la CNN se estudió a partir de simulaciones numéricas y empleando datos reales adquiridos con el radar RMA-12. Para las simulaciones numéricas se tomaron como métricas el sesgo y la desviación estándar de los estimados, y el desempeño de la CNN fue comparado con el de los algoritmos: DA y SPPP para la estimación de velocidad y ancho espectral en ausencia de clutter terrestre, y con ASPASS para las situaciones en las que el clutter contamina la señal. Tanto para el modo convencional, como para el modo *staggered*, las redes neuronales mostraron desempeños comparable al de los demás algoritmos, e inclusive, mejor desempeño en varias de las situaciones analizadas.

En los radares operativos, como fue mencionado, la mayor parte de los algoritmos de filtrado de clutter terrestre requieren de un clasificador previo que detecte la presencia del mismo, para de esta forma no incurrir en un filtrado innecesario de la señal radar. Por esta razón, se desarrolló un método utilizando machine learning que permite la clasificación de la composición de la señal meteorológica. El mismo posee la capacidad de asignar la señal recibida a una de las siguientes composiciones: *clutter + ruido*, *clutter + fenómeno + ruido*, *fenómeno + ruido* y *ruido*. Al igual que para la estimación de los momentos espectrales, en esta oportunidad se explota la estructura de la DEP para resolver el problema en cuestión. El método se desarrolló tanto para el modo de operación convencional, como para el modo de operación *staggered*. Para ambos modos se utilizan redes convolucionales de una dimensión, las que se entrenan utilizando datos sintéticos. En la tesis se presentan diversos experimentos por medio de simulaciones numéricas con el objetivo de estudiar el desempeño del algoritmo propuesto. Además, se emplean conjuntos de datos reales de los radares RMA-12 y RMA-11, este último situado en la ciudad de Termas de Río Hondo, para el modo convencional de operación, y conjuntos de datos del radar RMA-12 para el modo *staggered*.

La versión *staggered* del algoritmo de estimación de momentos espectrales del fenómeno meteorológico utilizando machine learning, y el método de clasificación de la composición de la señal radar se encuentran en proceso de escritura para ser sometidos, cada uno, a revisión por pares. Finalmente, también se realizó una contribución en la temática de la tesis a partir de participar en la extensión del algoritmo de estimación de velocidad Doppler media MPP [30] para que pueda ser utilizado en el modo de operación *staggered*, cuyo desarrollo no se incluye en esta tesis por no ser el autor principal del trabajo.

1.3. Organización de la tesis

El Capítulo 2 concentra los resultados que no son propios, pero que son necesarios para contextualizar el trabajo realizado en el marco de la tesis. Se presenta una introducción al radar Doppler meteorológico, se estudia su funcionamiento, sus componentes principales y el modelo de señal recibida. Además, se introducen conceptos importantes relacionados al procesamiento de la señal y los principales algoritmos utilizados con el objetivo de comparar sus desempeños con los métodos propuestos en el presente trabajo doctoral. Asimismo, se realiza una introducción a las técnicas de aprendizaje automático (en inglés, machine learning) y al aprendizaje profundo (en inglés, deep learning), y se describen las principales herramientas utilizadas en el aprendizaje supervisado empleando redes neuronales.

A partir del Capítulo 3 en adelante se presentan las diferentes contribuciones originales de la tesis. En particular, el tercer capítulo se divide en dos partes. En la primera

parte, se propone una corrección en la estimación del ancho espectral del clutter terrestre; y en la segunda parte se introduce el algoritmo GMAP-NU para el filtrado de clutter terrestre y estimación de momentos espectrales del fenómeno meteorológico, empleando el modo de operación *staggered* del radar.

En el Capítulo 4, se ataca el problema del filtrado de clutter terrestre y estimación de los momentos espectrales del fenómeno meteorológico para señales adquiridas en el modo de operación *staggered* con el algoritmo ASPASS. En primer lugar, se desarrolla el método y luego se estudia su desempeño empleando simulaciones numéricas y datos reales adquiridos con el radar RMA-12. En ambas ocasiones se compara el desempeño de ASPASS con otros métodos existentes.

Por su parte, en el Capítulo 5 se introduce la herramienta machine learning a la estimación de los momentos espectrales del fenómeno meteorológico de señales adquiridas en el modo convencional de operación del radar. Se propone una estructura de red neuronal con tres ramas densa, donde cada rama se utiliza para la estimación de un momento espectral, se emplean datos sintéticos en las etapas de entrenamiento y validación y, finalmente, se estudia el desempeño del método tanto con simulaciones numéricas como con datos reales adquiridos con el radar RMA-12.

Las ideas desarrolladas en el Capítulo 5 se extendieron para el modo de operación *staggered* y se presentan los resultados en el Capítulo 6. Teniendo en cuenta las particularidades del modo de operación, se sigue un procedimiento análogo al del Capítulo 5 tanto en la presentación del método como para el estudio de su desempeño.

Con el objetivo de detectar el clutter terrestre en la composición de la señal recibida, en el Capítulo 7 se presenta un clasificador basado en redes neuronales convolucionales, que permite identificar cuatro diferentes composiciones: *clutter + ruido*, *clutter + fenómeno + ruido*, *fenómeno + ruido* y *ruido*. El método se desarrolla para los modos de operación del radar mencionados. Finalmente, su desempeño se estudia mediante simulaciones numéricas y procesamiento de mediciones reales adquiridas con los radares RMA-11 y RMA-12.

Por último, en el Capítulo 8 se exponen conclusiones generales de la tesis, y se dejan planteadas líneas futuras de investigación en la temática.

Capítulo 2

Consideraciones generales

“La ciencia se compone de errores, que a su vez, son los pasos hacia la verdad. ”

— Julio Verne

2.1. Introducción

Los radares en general son sistemas activos que emiten ondas electromagnéticas con el propósito de iluminar objetos o reflectores de interés. Estas ondas electromagnéticas interactúan con los reflectores y parte de su energía es retransmitida hacia el radar, la que es convertida en una señal eléctrica por la antena receptora, para finalmente ser procesada por las diferentes etapas de recepción del radar. Una de las principales funciones de los radares es la de sensado remoto, debido a que permite extraer información relevante de los reflectores, los cuales se encuentran a distancias considerables respecto del mismo. Existen diferentes tipos de radares: radar primario, radar secundario, radar de apertura sintética, radar meteorológico, entre otros. Cada tipo de radar posee una o varias aplicaciones específicas. Por ejemplo, el radar primario se usa principalmente para el control del espacio aéreo y detección de aeronaves ilegales [43]. Por otro lado, el radar secundario se emplea en el control del tráfico aéreo, lo hace por medio de sus funciones de identificación y seguimiento de blancos, principalmente aeronaves [44]. Se encarga de entablar una comunicación con las aeronaves con el fin de determinar si están siguiendo adecuadamente la ruta preestablecida o no. Los radares de apertura sintética (SAR por sus siglas en inglés) son radares aerotransportados, principalmente sobre aviones o satélites [45]. Se utilizan para obtener imágenes de la superficie terrestre y poseen diversas aplicaciones, por ejemplo, en el sector agroindustrial para el estudio de los suelos y los cultivos, en el sector de vigilancia para identificar objetos en zonas de difícil acceso, etc. Asimismo, los radares meteorológicos son usados para estudiar

los fenómenos atmosféricos, en particular los hidrometeoros (lluvias, granizos, nevadas, etc.) debido a que el tipo de onda electromagnética que usan es capaz de penetrar estos fenómenos ofreciendo de esta forma gran información de los mismos. Con ellos se realizan pronósticos a corto y mediano plazo de las condiciones climáticas, posibilitando dar alertas tempranas para evitar catástrofes de diversas índoles.

En la sección 2.2 se realiza una introducción general al radar meteorológico. Se mencionan algunos de sus componentes principales y se describe su modo de funcionamiento. Además, se estudia el modelo de señal recibida y se definen conceptos importantes como volumen de resolución, dimensiones de muestreo, ambigüedades, entre otros, los cuales son relevantes para comprender el tipo de procesamiento que se llevará a cabo. En la sección 2.3 se definen los productos de radar meteorológico Doppler, conformados por los tres primeros momentos de la densidad espectral de potencia de la señal en la dimensión tiempo lento. En la sección 2.4 se describen algoritmos de procesamiento Doppler, tanto para la estimación de los momentos espectrales, como para el filtrado de clutter terrestre, en lo que se denominará modo de operación convencional del radar, es decir cuando se emplea una única frecuencia de repetición de pulso. Por otra parte, en la sección 2.5 se describen algoritmos de procesamiento Doppler del mismo tipo, pero para lo que se conoce como modo de operación *staggered*, es decir cuando el radar alterna la frecuencia de repetición de pulsos. En la sección 2.6 se realiza una breve descripción de las mediciones de radar utilizadas en la validación de los algoritmos propuestos a lo largo de la tesis. Finalmente, en la Sección 2.7 se realiza una breve introducción a las técnicas de machine learning y deep learning. También se presentan las principales herramientas utilizadas para el entrenamiento de las redes neuronales.

2.2. Radar meteorológico

El radar meteorológico es un sistema complejo, que se compone de diferentes subsistemas, los cuales poseen funciones específicas. La Figura 2.1 muestra algunos de los componentes principales. Entre ellos se encuentran:

- Transmisor: encargado de generar la forma de pulso a emitir, la modulación de la señal a la frecuencia de microondas y la amplificación a los niveles de potencia requeridos.
- Antena: su función es la de un adaptador, en la transmisión transforma la señal de un medio confinado para ser transmitida en un medio no confinado, mientras que realiza el proceso inverso en la recepción. En general, la antena de estos radares presenta forma de paraboloide de revolución y posee un patrón de radiación, $f(\theta, \phi)$, fuertemente concentrado en el lóbulo principal [3]. El control de antena se ocupa de la rotación y del ángulo de elevación de la misma.

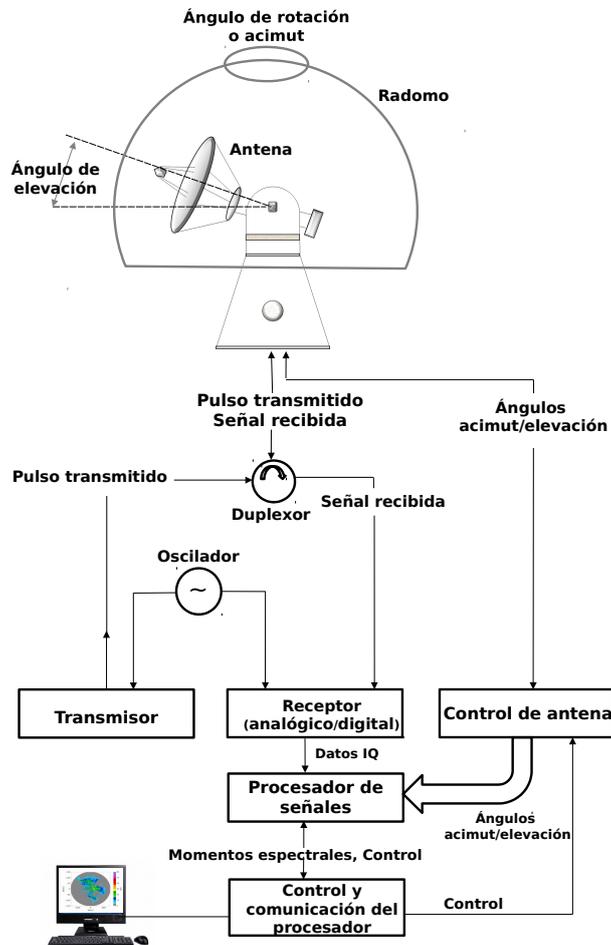


Figura 2.1: Componentes principales del radar.

- Receptor: en general se trata de un esquema heterodino, en el que existe una etapa de amplificación de bajo ruido, una etapa de conversión a frecuencia intermedia, filtrado, demodulación en cuadratura y la digitalización de la señal (que puede tener lugar en distintos puntos del receptor dependiendo de la implementación elegida).
- Procesador de señales: encargado de procesar la señal a la salida del receptor, arroja las primeras variables necesarias para calcular los productos meteorológicos.
- Radomo: recubrimiento de la antena con el fin de protegerla, diseñado para ser transparente a las ondas EM en la región espectral de interés.

La Figura 2.2 muestra un diagrama en bloques simplificado del radar con receptor

heterodino. En la etapa de transmisión el pulso generado es modulado, amplificado y direccionado a través del duplexor hacia la antena en forma de señal eléctrica. Allí se convierte en una onda electromagnética y es transmitida. En la etapa de recepción, la onda recibida por la antena es convertida en una señal eléctrica, la que es direccionada por el duplexor hacia el módulo de recepción, donde es amplificada usando un amplificador de bajo ruido (LNA por sus siglas en inglés), convertida a frecuencia intermedia (IF por sus siglas en inglés) utilizando un mezclador, filtrada empleando filtro adaptado, y demodulada a banda base por medio de un demodulador en fase y cuadratura. Finalmente, la señal es digitalizada y almacenada en una matriz de datos complejos para su posterior procesamiento usando el procesador de señales.

El duplexor permite que una misma antena se utilice para transmitir y recibir la señal, lo cual hace que el radar sea monoestático. En la etapa de transmisión, aísla el receptor del transmisor, y viceversa para la etapa de recepción. El filtro adaptado se utiliza con el objetivo de maximizar la SNR. El mismo se puede implementar en varios lugares de la cadena de recepción, lo más común es encontrarlo después de la conversión a IF [2], o después de la demodulación. Por su parte, para la demodulación a banda base la señal se divide en dos canales. El primero, llamado en fase, I, (en inglés, in phase), y el segundo canal llamado en cuadratura, Q, (en inglés, in quadrature). En ambos canales la entrada se multiplica por una señal de referencia senoidal a la frecuencia intermedia (generada con un oscilador local), siendo la diferencia de fase de la señal de referencia de 90° entre los canales I y Q. La razón por la cual se necesitan ambos canales es que con uno solo no se obtiene toda la información de la fase de la señal recibida de forma no ambigua [6]. La digitalización de la señal puede tener lugar en distintos puntos de la cadena de recepción y la misma depende de la implementación adoptada. Diseños antiguos requerían digitalizar la señal en banda base. Sin embargo, la velocidad de los conversores A/D actuales permiten muestrear en etapas de frecuencia intermedia y la tendencia es digitalizar la señal cada vez más cerca de la antena.

2.2.1. Señal recibida

La señal meteorológica se obtiene a partir de la suma de las contribuciones de las numerosas partículas que componen el hidrometeoro que se observa. Cada pequeña partícula puede pensarse como un reflector puntual, que compone el objetivo distribuido. Inicialmente, la onda transmitida por la antena del radar se propaga en el espacio hasta alcanzar, por ejemplo, una nube. Cuando el frente de la onda incidente intercepta la nube, excita sus partículas, generando dipolos eléctricos oscilantes, los cuales emiten en todas las direcciones, ondas electromagnéticas de igual frecuencia que la onda incidente. En particular, una de esas direcciones es la del receptor del radar, que en el caso del radar monoestático coincide con la dirección de la onda incidente. Esto da

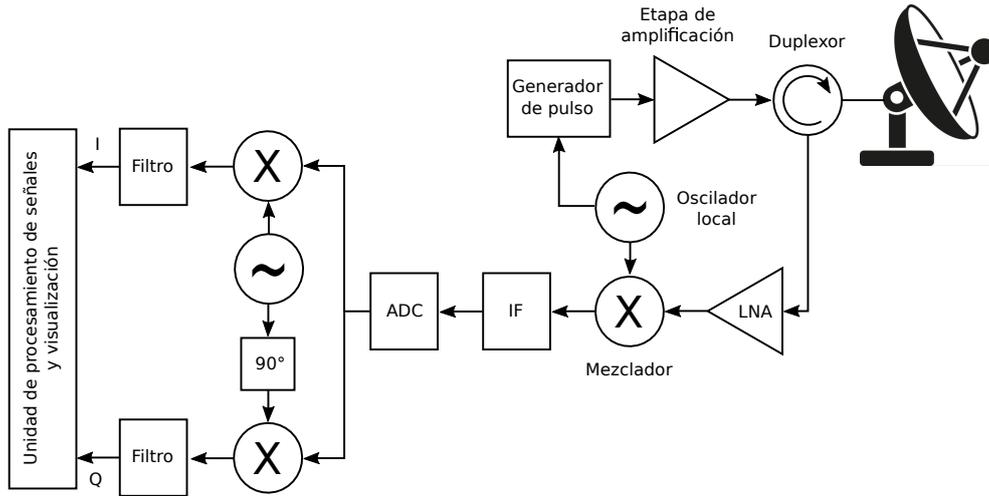


Figura 2.2: Diagrama en bloques simplificado del radar con receptor heterodino.

lugar al proceso de dispersión (en inglés, *scattering*) hacia el radar, o retrodispersión (backscattering en inglés). Por su parte, los campos incidente y el generado por la dispersión continúan penetrando en la nube, lo que replica el proceso de excitación de las nuevas partículas alcanzadas y la correspondiente dispersión hacia el radar. Cabe destacar que no toda la energía de la onda incidente es dispersada, una fracción de esta energía es absorbida por el medio. Otro aspecto importante, consiste en que la energía de estas ondas no es necesariamente la misma en todas las direcciones, depende de varios factores, entre los que vale mencionar: la polarización de la onda incidente, la forma geométrica de los reflectores y su orientación respecto a la onda incidente. En el modelado matemático de la propagación, la dependencia con estos factores se pone de manifiesto a través del cálculo de la matriz de dispersión \mathbf{S} , la cual relaciona los campos eléctricos incidente y dispersado por el reflector [8].

Una manera de obtener la expresión de la señal recibida por el radar, consiste en dividir el problema en dos etapas. En primer lugar, se considera la señal producida por un único reflector puntual. Luego, se extiende la idea a objetivos distribuidos, integrando las contribuciones de reflectores puntuales diferenciales en el volumen conformado por la *celda de resolución* del radar.

Suponiendo que los campos presentan variaciones sinusoidales, la representación fasorial de la onda transmitida, cuando la misma se encuentra lo suficientemente alejada de la antena, es decir en la región conocida como *campo lejano*, está dada por

$$\mathbf{E}_i(r, \theta, \phi, t) = \frac{\mathbf{E}_o(\theta, \phi)}{r} e^{(j2\pi f_c(t - \frac{r}{c}) + j\psi_t)}, \quad (2.1)$$

donde r es la distancia desde la antena hasta el punto donde se calcula el campo eléctrico; f_c es la frecuencia de portadora; c la velocidad de la luz en el vacío; t es el tiempo transcurrido desde la emisión de la onda; ψ_t es una fase inicial debido a la

transmisión; y $\mathbf{E}_o(\theta, \phi)$ es la amplitud inicial del campo, que depende de la ganancia G de la antena, la potencia transmitida P_t , entre otras magnitudes y es función de los ángulos acimut $\phi \in [0, 2\pi]$ y elevación $\theta \in [0, \pi]$ vistos desde un sistema esférico de coordenadas.

El plano de polarización se define como aquel perpendicular entorno a un punto a la dirección de propagación. Las componentes de \mathbf{E}_i en este plano aportan información de la polarización de la onda. Las ondas pueden tener polarización elíptica, circular o lineal [3]. El campo eléctrico \mathbf{E}_b dispersado por el reflector, dependerá de \mathbf{S} . En general, la polarización de la onda dispersada varía según las propiedades dieléctricas y geométricas del reflector [8]. La tensión eléctrica generada en los bornes de la antena por la onda dispersada recibida es

$$V(t) = Ae^{(j2\pi f_c(t - \frac{2r}{c}) + j\psi_t)} U\left(t - \frac{2r}{c}\right) + V_n(t), \quad (2.2)$$

siendo j la unidad imaginaria, $2r$ es la distancia total recorrida por la onda incidente y dispersada; A es una amplitud compleja, $|A|e^{j\psi_s}$, donde ψ_s es el corrimiento de fase producido por la dispersión y $|A|$ está íntimamente relacionado con la potencia recibida en la antena del radar, que, además, depende de varios factores que se verán más adelante cuando se presente la *ecuación radar* para un reflector puntual; U es la función definida como $U(t) = 1$ si $t \in (0, \tau)$ y cero en caso contrario, donde τ es la duración del pulso transmitido; y $V_n(t)$ representa ruido aditivo. La fase ψ_e de la señal recibida, sin considerar la contribución del ruido es

$$\psi_e = -\frac{4\pi r}{\lambda} + \psi_t + \psi_s. \quad (2.3)$$

Como en todo sistema de comunicaciones, el ruido va a estar presente. Existen diferentes fuentes de ruido, entre ellas se encuentran: radiaciones provenientes del espacio exterior, radiaciones de las moléculas de oxígeno y vapor de agua de la atmósfera terrestre, componentes electrónicos propios del radar y radiaciones producidas por el hombre, principalmente en las grandes ciudades [3].

Las expresiones de las componentes en fase, I, y en cuadratura, Q son las siguientes

$$I(t) = \frac{|A_g|}{\sqrt{2}} U\left(t - \frac{2r}{c}\right) \cos(\psi_e) + I_n(t) \quad (2.4a)$$

$$Q(t) = \frac{|A_g|}{\sqrt{2}} U\left(t - \frac{2r}{c}\right) \sen(\psi_e) + Q_n(t), \quad (2.4b)$$

donde $I_n(t)$ y $Q_n(t)$ son las componentes en fase y en cuadratura del ruido. Luego, la envolvente compleja a la salida del receptor es de la forma $V_r(t) = I(t) + jQ(t)$. Cabe remarcar que en las ecuaciones (2.4a) y (2.4b) la amplitud A_g tiene en cuenta

la atenuación que produce el filtro adaptado por poseer ancho de banda finito. De acuerdo con la teoría, la respuesta impulsiva de estos filtros debe tener la misma forma de onda que la envolvente compleja de la señal transmitida, espejada en el tiempo y conjugada. Cuando se transmite un pulso sinusoidal sin modulación, la envolvente compleja es un pulso rectangular y la respuesta impulsiva correspondiente, también es una función con forma rectangular. Desde el punto de vista práctico, este tipo de filtros presentan limitaciones para ser implementados, debido a los cambios abruptos que presenta la señal. Por esta razón, las respuestas al impulso de estos filtros, en general, son aproximaciones a las formas teóricas. En radares más modernos, estos filtros se implementan de forma digital, en los cuales se utiliza como respuesta al impulso la señal transmitida muestreada e invertida en el tiempo [8].

Para el caso de N_s reflectores puntuales, la señal recibida por el radar está formada por la superposición de muchos ecos provenientes de cada reflector en particular. La señal a la salida del receptor está dada por

$$V_r(t) = \frac{1}{\sqrt{2}} \sum_{l=1}^{N_s} A_l W_l e^{-j\frac{4\pi r_l}{\lambda}} + V_{nr}(t) = I_r(t) + jQ_r(t), \quad (2.5)$$

donde A_l es la amplitud compleja de la señal para cada reflector antes del filtrado; W_l es un número complejo que pesa la contribución de los reflectores en la dirección radial, su valor está determinado por la forma del pulso transmitido y por el filtro adaptado utilizado [3]; $V_{nr}(t)$ representa el ruido total a la salida del receptor. Sin pérdida de generalidad, en la ecuación (2.5), se supuso que $\psi_t = 0$. La naturaleza aleatoria de la posición de los reflectores r_l , conllevan a que $V_r(t)$ deba ser modelada como un proceso estocástico. Como cada una de las componentes $I_r(t)$ y $Q_r(t)$ es la superposición de numerosos términos aleatorios, donde ninguno domina por sobre los demás, a partir del teorema central del límite [46], es posible demostrar que la distribución de probabilidad gaussiana de media cero y varianza σ es un buen modelo para la señal [3].

Volumen de resolución

Se define como volumen de resolución, V_6 , la región del espacio en la cual todos los reflectores contribuyen a la señal recibida en el radar. Este volumen depende del patrón de radiación normalizado de la antena $f(\theta, \phi)$ y de la función de peso en rango $W(r)$ [3], los cuales son los encargados de pesar las contribuciones en las direcciones angulares y radial, respectivamente. En términos de potencia, la contribución de cada reflector depende de su posición dentro de este volumen y está pesada por $f^4(\theta_l, \phi_l)|W(r_l)|^2$, donde l especifica la posición de cada reflector respecto a la dirección de máxima radiación. En la Figura 2.3 se muestra un escenario meteorológico, en el cual se identifica el volumen de resolución. Matemáticamente, este volumen se escribe como aquella

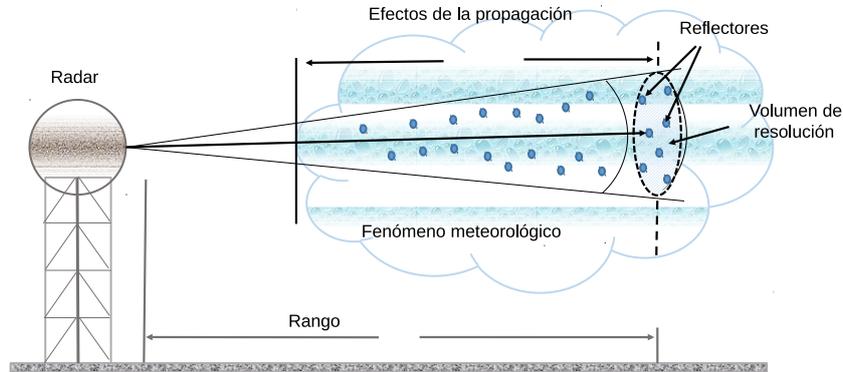


Figura 2.3: Volumen de resolución.

región tal que el valor $f^4(\theta_l, \phi_l)|W(r_l)|^2$ se encuentre dentro de $1/4$ del valor máximo (6 dB por debajo del valor máximo). Estrictamente, los reflectores que se encuentren fuera de V_6 contribuirán a la señal recibida pero esa contribución será muy débil y a los fines prácticos despreciables, excepto en el caso de que dos volúmenes de resolución contiguos tengan mucha diferencia en cuanto a la dispersión cruzada promedio de los reflectores [8].

2.2.2. Ecuación radar meteorológico

La *ecuación radar* es una ecuación determinística, que relaciona la potencia recibida por el radar con la potencia transmitida, ciertos parámetros del sistema y las pérdidas atmosféricas. Si bien en su deducción se hacen consideraciones que simplifican el problema, es de utilidad en el diseño del sistema.

En aplicaciones en las que el objetivo es puntual, con sección de dispersión cruzada hacia atrás (en inglés, backscattering cross section) σ_b , y se encuentra a una distancia r respecto del radar, la *ecuación radar* es de la forma [3],

$$P_r = \frac{P_t G^2 \lambda^2 \sigma_b f^4(\theta, \phi)}{(4\pi)^3 r^4 l_i(r) l_v(r)}, \quad (2.6)$$

donde P_r y P_t son las potencias recibida y transmitida, respectivamente; G y $f(\theta, \phi)$ es la ganancia; $l_i(r)$ y $l_v(r)$ son términos que dan cuenta de las pérdidas debido a la propagación de la onda que ocurren a la ida y a la vuelta, respectivamente. Estos términos, en general, toman valores diferentes y dependen de la polarización de la onda. En la problemática que se aborda en esta tesis, se considera que tanto la onda transmitida como la onda recibida poseen polarización lineal horizontal (paralela a la superficie terrestre), por lo que se admite que $l_i(r) = l_v(r) = l(r)$.

Cuando los objetivos poseen una extensión comparable al volumen de resolución del radar, la consideración de objetivo puntual deja de ser válida. En esas situaciones los objetivos se denominan distribuidos. Una forma de interpretar estos objetivos consiste en considerar que se componen de la contribución de numerosos reflectores puntuales. Un caso particular, son los objetivos meteorológicos.

Es posible extender la ecuación (2.6) para contemplar objetivos meteorológicos, en esos casos se hace referencia a la *ecuación radar meteorológico*. La potencia media $E[P_r(r_o)]$ a la salida del receptor en este caso, suponiendo que las pérdidas y la sección cruzada promedio por unidad de volumen $\eta(r)$ [3] son constantes se puede escribir como

$$E[P_r(r_o)] = \frac{P_t G^2 \lambda^2 \eta(r_o)}{(4\pi)^3 r_o^2 l^2(r_o)} \int_0^{r_2} |W(r)|^2 dr \int_0^{2\pi} \int_0^\pi f^4(\theta, \phi) \sin(\theta) d\theta d\phi, \quad (2.7)$$

donde r_o es la distancia al centro del volumen de resolución y r_2 es una distancia máxima, para la cual los reflectores dejan de contribuir a la señal recibida tomada en un instante de tiempo determinado.

Suponiendo que el patrón de antena tiene simetría circular y forma gaussiana, entonces la potencia media $E[P_r(r_o)]$ resulta

$$E[P_r(r_o)] = \frac{P_t G^2 G_s c T_p \pi \lambda^2 \eta(r_o) \theta_1^2}{(4\pi)^3 r_o^2 l^2(r_o) l_r 16 \ln(2)}, \quad (2.8)$$

donde θ_1 es el ángulo de mitad de potencia de la antena, T_p es el tiempo de duración del pulso transmitido, G_s es la ganancia neta de todo el sistema de recepción sin incluir la antena y l_r es una pérdida debido al ancho de banda finito del filtro adaptado [3]. La potencia calculada a la salida del receptor se relaciona con los valores $I_r(r_o)$ y $Q_r(r_o)$ de la ecuación (2.4) mediante $P_r(r_o) + P_n = I_r^2(r_o) + Q_r^2(r_o)$, donde P_n es la potencia debido al ruido.

Conformación de la señal

El propósito de los radares meteorológicos consiste en estudiar los eventos relacionados con el clima, como ser los distintos tipos de precipitaciones: lluvia, granizo, nevadas. Este tipo de reflectores se denominarán meteorológicos.

La onda incidente no solo es reflejada, o dispersada, por los objetivos de interés, también se producen reflexiones no deseadas en el entorno de dichos objetivos. En especial para ángulos de elevación bajos, dentro de cada volumen de resolución, además de los reflectores meteorológicos, es posible encontrar la presencia de montañas, edificios, vegetación, insectos, etc. A las reflexiones producidas por cualquier fuente que no sea los reflectores meteorológicos se las denomina *clutter*. En general, la señal recibida por el radar para cada instante de tiempo estará conformada por tres términos: reflexiones

debidas al objetivo de interés, clutter y ruido aditivo.

Existen diversos tipos de clutter, que se caracterizan por afectar de forma diferente a la señal de interés. Entre ellos caben destacar: el clutter marítimo, proveniente de las reflexiones producidas sobre las olas del mar [47, 48]; el clutter eólico, que debe su nombre a que su fuente son las aspas de los molinos de los parques eólicos [49, 50]; clutter biológico, debido a que son reflexiones que causan bandadas de aves o enjambres de insectos [51]; y el clutter terrestre proveniente, principalmente, de montañas, edificios y árboles [3]. El clutter no solo se debe a las reflexiones que arriban a la antena a través de su lóbulo principal, el cual está íntimamente relacionado con el volumen de resolución V_6 . En ocasiones, estas reflexiones no deseadas arriban por medio de los lóbulos laterales, como consecuencia de que la dispersión cruzada promedio de estos reflectores, en general, suele ser significativamente mayor que para los reflectores meteorológicos.

Matemáticamente, el modelo de la señal compleja a la salida del demodulador en cuadratura, en el caso más general, es de la forma

$$V_r = V_{pr} + V_{cr} + V_{nr} \quad (2.9)$$

donde V_{pr} da cuenta de la contribución de los reflectores meteorológicos, V_{cr} corresponde al término de clutter y V_{nr} denota el ruido aditivo.

2.2.3. Muestreo

En su modo de operación estándar, el radar transmite un pulso de duración T_p , luego existe un tiempo de guarda, t_e , y a continuación se abre una ventana temporal de recepción. Pasado este tiempo, se transmite un nuevo pulso, lo que da comienzo a un ciclo como el anterior. Este proceso se repite para una serie de pulsos. El tiempo entre pulsos consecutivos se denomina intervalo de repetición de pulsos (PRI de sus siglas en inglés) y se denotará como T_u . El inverso de T_u es lo que se conoce como frecuencia de repetición de pulsos (PRF de sus siglas en inglés). En los radares meteorológicos la PRF se encuentra entre los cientos de Hz hasta varios kHz [3]. La Figura 2.4 muestra un esquema de transmisión y recepción donde se presentan algunos de los tiempos definidos.

La señal recibida debida a cada eco, además de ser demodulada usando un detector coherente como se explicó anteriormente, es muestreada a una frecuencia de muestreo f_s y almacenada en una memoria digital. f_s toma valores en el orden de los MHz. Los instantes de muestreo, $t_r = \frac{n}{f_s}$ con n entero, se corresponden a las dispersiones ocurridas en un mismo volumen de resolución, por lo que la muestra se encuentra asociada a la distancia al centro de ese volumen de resolución $r_r = \frac{ct_r}{2}$. Por este motivo, en general

se hace referencia a estas muestras como celdas de rango. Es importante notar que la distancia temporal de dos celdas de rango consecutivas no definen la resolución en rango del radar, Δ_r , sino la diferencia de distancia entre los centros de los volúmenes de resolución respectivos. La resolución en rango del radar, Δ_r , está relacionada con el tamaño de V_6 en la dirección radial, el cual para la situación teórica de transmisión de un pulso rectangular y respuesta impulsiva del filtro adaptado también con forma rectangular es $\Delta_r = \frac{cT_p}{2}$.

Una manera de interpretar el almacenamiento de los datos, consiste en agruparlos en una matriz de datos complejos en fase y cuadratura (IQ, por sus siglas en inglés) como se presenta en la Figura 2.5, donde p es el número total de pulsos transmitidos [6]. Las filas corresponden a las muestras tomadas sobre la señal recibida en cada ventana de recepción, es decir están asociadas a distintos rangos. Para una dada fila, las columnas corresponden a muestras tomadas a la misma distancia, adquiridas sobre los diferentes pulsos de la serie transmitida.

Como consecuencia de la diferencia que existe en los órdenes de magnitud de la frecuencia de muestreo f_s y de la PRF, a la dimensión de muestreo correspondiente a las filas se la denomina tiempo rápido y, en contraposición, a la dimensión correspondiente a las columnas se la denomina tiempo lento [6].

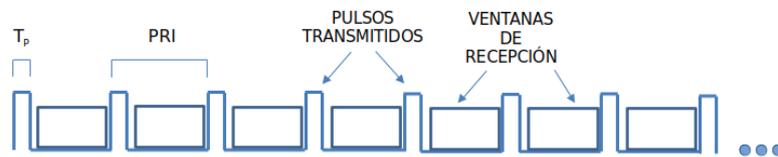


Figura 2.4: Esquema de transmisión y recepción de pulsos.

Ambigüedades

Del juego de ecuaciones (2.4) se observa que para los tiempos de duración de pulso T_p del orden de los microsegundos, la fase de la señal recibida varía muy poco, dificultando la detección de cambios de fase a la tasa de muestreo f_s . Por este motivo, lo que se conoce como procesamiento Doppler de la señal, que depende justamente de dicha fase, se realiza en la dimensión tiempo lento, que posee una escala de tiempo del orden de milisegundos. Debido a que la antena del radar meteorológico gira a una velocidad angular w_g , el lóbulo principal de la misma solamente iluminará a un reflector puntual durante un número finito M de pulsos. Al intervalo de tiempo MT_u se lo denomina intervalo de procesamiento coherente (CPI de sus siglas en inglés). El procesamiento Doppler se lleva a cabo por CPI, para cada celda de rango (filas de la matriz de datos IQ). Las muestras de la señal en esta dimensión corresponden a una misma distancia, y poseen una separación temporal de T_u , de donde resulta que la frecuencia máxima que

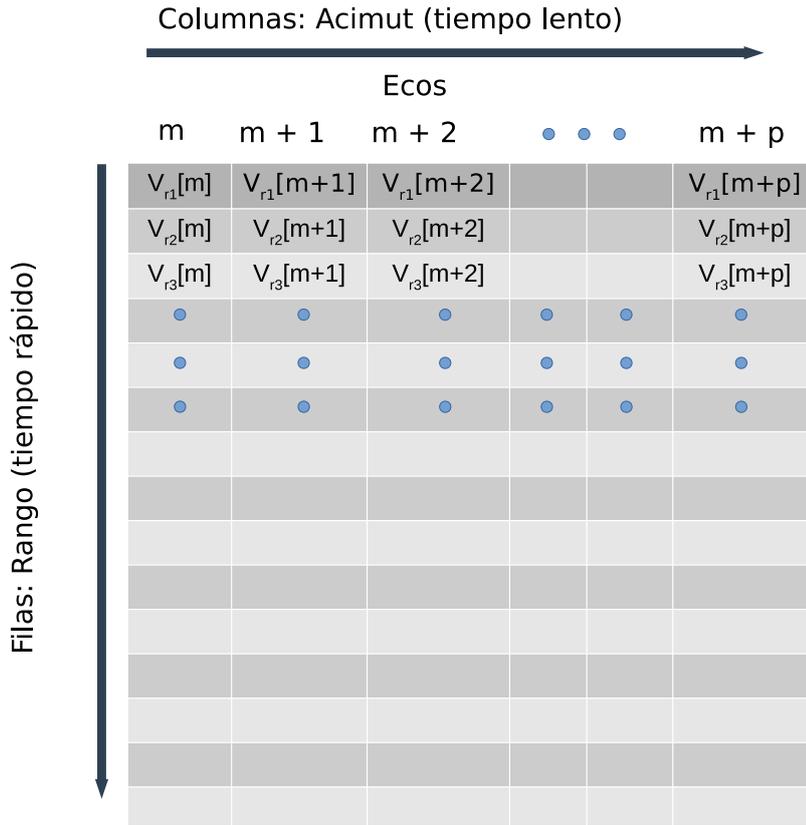


Figura 2.5: Matriz de datos complejos IQ.

puede resolverse sin ambigüedad es $f_a = \frac{1}{2T_u}$ [52]. La velocidad $v_a = \frac{\lambda f_a}{2} = \frac{\lambda}{4T_u}$, asociada a f_a , se conoce como velocidad máxima no ambigua. Si el reflector meteorológico tiene una velocidad Doppler media mayor en módulo que v_a , debido a la periodicidad de su espectro producto del muestreo, el mismo quedará solapado (en inglés, aliasing) dentro de los límites $[-v_a, v_a]$.

La segunda ambigüedad está relacionada con el rango máximo no ambiguo, R_a , que puede resolverse. En principio, es de esperar que un eco recibido en un instante t_n , se encuentre asociado a una reflexión producida a la distancia $R_n = \frac{ct_n}{2}$. Sin embargo, estrictamente, los ecos recibidos en una dada ventana de recepción pueden deberse a reflexiones producidas en objetivos lejanos, debido a la propagación de pulsos enviados previamente. En general, un eco recibido en un instante t_n , se encuentra asociado a una distancia $R_n + k\frac{cT_u}{2} = \frac{ct_n}{2} + k\frac{cT_u}{2}$, donde k es un entero no negativo desconocido. A partir de este razonamiento resulta $R_a = \frac{cT_u}{2}$.

La Figura 2.6 muestra un ejemplo de ambigüedad en rango, para el caso $k = 1$. Los ecos identificados con los números 1 y 2, son producto, respectivamente, de reflexiones de los pulsos 1 y 2, sobre reflectores meteorológicos distantes entre sí $\frac{cT_u}{2}$. Sin embargo, arriban al radar en el mismo instante de tiempo, por lo que no se podrá resolver

correctamente la posición del reflector más alejado.

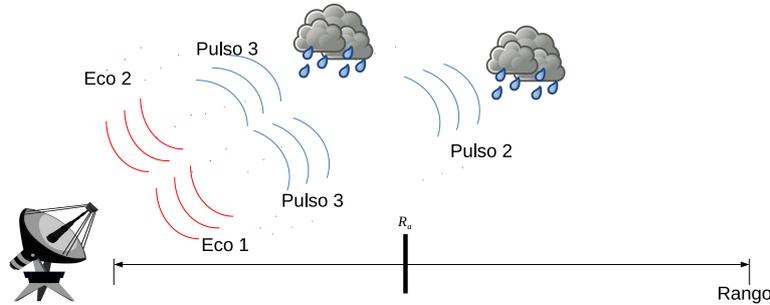


Figura 2.6: Ambigüedad en rango.

Cuando un radar opera en el modo convencional, es decir con un único PRI, existe una relación de compromiso entre el rango máximo no ambiguo y la velocidad máxima no ambigua. El primero depende proporcionalmente con el PRI, y el segundo depende inversamente proporcional con el PRI, por lo tanto, aumentar uno implica disminuir el otro. Una forma de incrementar v_a sin degradar R_a consiste en transmitir los pulsos con diferentes PRI. A este modo de operación se lo conoce como modo escalonado (en inglés, *staggered*) [3]. La variante más aceptada en los radares meteorológicos, es la que emplea dos valores diferentes de PRI, T_1 y T_2 , con una relación entre ellos dada por $T_1 = 2T$ y $T_2 = 3T$ [17], donde $T = T_2 - T_1$. A este modo en particular se lo denomina *staggered 2/3*.

2.3. Momentos espectrales

En aplicaciones de radar Doppler meteorológico, los tres primeros momentos de la densidad espectral de potencia de la señal conforman magnitudes que aportan información útil a la hora de estudiar los fenómenos meteorológicos. El momento de orden cero, o potencia de la señal, p_p , está relacionado con el contenido de agua líquida o la tasa de precipitación dentro del volumen de resolución. El momento de primer orden, o velocidad Doppler media, v_p , está relacionado con el movimiento del aire, el cual puede estar acercándose o alejándose respecto del radar, y con el movimiento de los hidrometeoros. El momento de segundo orden, o ancho del espectro, σ_p , cuantifica la dispersión de velocidades, debido a turbulencias o vientos de cizalladura [3]. Otro producto meteorológico que está íntimamente relacionado con el momento de orden cero es la reflectividad. Se demuestra en [3] que la reflectividad es proporcional a la potencia de la señal si los tamaños de las gotas de agua son menores que la longitud de onda

del radar. Con la reflectividad los meteorólogos hacen estimaciones de la cantidad de lluvia que caerá. Además, su valor contribuye a inferir el tipo de precipitación (nevada, granizo, lluvia ligera, lluvia fuerte, etc).

2.3.1. Densidad espectral de potencia (DEP)

Si el tiempo en el cual el lóbulo principal de la antena ilumina un reflector es tal que no ocurren cambios significativos en la estadística de la señal recibida por el radar, es válida la consideración de que el proceso que controla la dispersión es estacionario. En especial, si la media estadística es constante y la autocorrelación sólo depende de la diferencia de instantes en los que se observa al proceso aleatorio, entonces dicho proceso es estacionario en sentido amplio [46]. La señal recibida por los radares meteorológicos son un buen ejemplo de este tipo de procesos estacionarios [3]. Se puede demostrar que la función gaussiana es un buen modelo para la autocorrelación, $R_p(mT_u)$, de la señal proveniente de un fenómeno meteorológico en la dimensión tiempo lento para un determinado instante en la dimensión tiempo rápido t_{r_o} , o rango r_o , es decir [3]

$$R_p(mT_u) = E \{V_{r_o}^*(kT_u)V_{r_o}((k+m)T_u)\} = p_p e^{-\frac{8\pi^2\sigma_p^2 m^2 T_u^2}{\lambda^2}} e^{-j\frac{4\pi v_p m T_u}{\lambda}}. \quad (2.10)$$

A partir del teorema de *Wiener – Khinchin* [46], la DEP se obtiene como la transformada de Fourier (TF) de la autocorrelación, entonces

$$S_p^f(f) = \mathcal{F}\{R_p(mT_u)\} = \frac{p_p}{\sqrt{2\pi}\sigma_p^f} e^{-\frac{(f-f_p)^2}{2\sigma_p^{f2}}}, \quad (2.11)$$

donde $\mathcal{F}\{\cdot\}$ es el operador de la TF, f_p es la frecuencia media del hidrometeoro y σ_p^f es el ancho espectral en unidades de Hz. Aplicando la transformación $f = -\frac{2v}{\lambda}$ que lleva del dominio de las frecuencias al dominio de las velocidades se obtiene

$$S_p(v) = \frac{p_p}{\sqrt{2\pi}\sigma_p} e^{-\frac{(v-v_p)^2}{2\sigma_p^2}}, \quad (2.12)$$

siendo $v_p = -\frac{f_p\lambda}{2}$ y $\sigma_p = \frac{\sigma_p^f\lambda}{2}$.

La DEP aporta información de la distribución de potencia respecto a la velocidad Doppler. De la ecuación (2.12) se observa que la DEP está centrada en la velocidad Doppler media del fenómeno meteorológico. Para el caso de señal proveniente solamente de clutter terrestre, la DEP también se modela con forma gaussiana, de varianza σ_c^2 , pero centrada en la velocidad Doppler media cero. La señal de ruido V_{nr} se modela como ruido blanco gaussiano [3].

Considerando el caso más general, la señal recibida, será la suma de las contribuciones de fenómeno meteorológico, de clutter terrestre y de ruido blanco. Bajo la hipótesis

de que las tres señales son independientes, luego la DEP de la señal recibida, $S(v)$, está dada por

$$S(v) = S_p(v) + S_c(v) + S_N(v), \quad (2.13)$$

donde $S_p(v)$, $S_c(v)$ y $S_N(v)$ son las densidades espectrales del fenómeno meteorológico, del clutter terrestre y del ruido blanco, respectivamente, con $S_N(v) = \frac{2P_n T_u}{\lambda}$.

2.4. Procesamiento Doppler

Si el radar está operando en su modo convencional, la señal de la matriz de datos IQ en la dimensión tiempo lento resulta muestreada de forma uniforme, siendo posible aplicar técnicas clásicas de procesamiento como la Transformada Discreta de Fourier (DFT de sus siglas en inglés), entre otras [3].

El objetivo de esta etapa de procesamiento consiste en obtener estimaciones de los momentos espectrales, que dan lugar a las variables Doppler de interés. Sin embargo, como se mencionó, en ocasiones las reflexiones deseadas se encuentran oscurecidas por contribuciones de clutter. Por lo tanto, previo a la estimación de dichos momentos es necesario remover la señal no deseada. En esta sección se describen, brevemente, algoritmos comúnmente utilizados con esta finalidad y que servirán de patrón a los fines comparativos a lo largo de la tesis.

2.4.1. Pulse Pair Processing (PPP)

Pulse Pair Processing (PPP) es un algoritmo de estimación de los momentos espectrales a partir de estimados de la autocorrelación, \hat{R} , de la señal recibida. Suponiendo que la señal sólo se compone de contribuciones del fenómeno meteorológico más ruido, entonces la potencia del fenómeno se estima como la autocorrelación de la señal en el instante cero, descontando la potencia estimada de ruido \hat{P}_n , es decir

$$\hat{p}_p = \hat{R}(0) - \hat{P}_n \quad (2.14)$$

Para un determinado rango y CPI una posibilidad para estimar $\hat{R}(0)$ consiste en emplear

$$\hat{R}(0) = \frac{1}{M} \sum_{m=0}^{M-1} |V_r(m)|^2. \quad (2.15)$$

Valiéndose del teorema de *Wiener–Khinchin*, es posible escribir la autocorrelación evaluada en T_u en términos de la DEP, como

$$R(T_u) = e^{j2\pi f_p T_u} \int_{-1/2T_u}^{1/2T_u} S(f) e^{j2\pi T_u (f - f_p)} df, \quad (2.16)$$

donde f_p es la frecuencia Doppler media, vinculada con la velocidad Doppler media mediante $v_p = -f_p\lambda/2$. Notar que cuando la integral de la ecuación (2.16) es real, entonces sólo el término $e^{j2\pi f_p T_u}$ define la fase de $R(T_u)$. Esto implica que la parte imaginaria de la integral debe ser cero,

$$\epsilon_s = \int_{-1/2T_u}^{1/2T_u} S(f) \text{sen}[2\pi T_u(f - f_p)] df = 0, \quad (2.17)$$

condición que se logra cuando $S(f)$ tiene simetría par respecto de f_p . Es importante destacar que PPP sólo requiere simetría de la DEP para deducir el estimador de la velocidad Doppler media sin importar qué forma específica la misma posea.

Teniendo en cuenta que un estimador de la autocorrelación para un determinado rango y CPI evaluada en T_u , es

$$\hat{R}(T_u) = \frac{1}{M-1} \sum_{m=0}^{M-2} V_r^*(m) V_r(m+1), \quad (2.18)$$

luego, el estimador de la velocidad v_p de PPP resulta

$$\hat{v}_p = -\frac{\lambda}{4\pi T_u} \arg(\hat{R}(T_u)). \quad (2.19)$$

En contraposición con lo que ocurre para la velocidad, para obtener un estimador del ancho espectral, esta técnica requiere hacer uso de una forma específica para la DEP. Una posibilidad es emplear el modelo de autocorrelación con forma gaussiana descrito en la sección 2.3.1.

Evaluando la ecuación (2.10) en los instantes 0 y T_u , y haciendo el cociente de los resultados, luego de una serie de pasos algebraicos se obtiene el estimador del ancho espectral en función de $\hat{R}(T_u)$ y \hat{p}_p ,

$$\hat{\sigma}_p = \frac{\lambda}{2\pi T_u \sqrt{2}} \left| \ln \left(\frac{\hat{p}_p}{|\hat{R}(T_u)|} \right) \right|^{\frac{1}{2}}. \quad (2.20)$$

Cuando a lo largo del trabajo se mencionen los estimadores utilizando PPP, se estará haciendo referencia a las ecuaciones (2.14), (2.19) y (2.20) para cada uno de los tres primeros momentos espectrales, respectivamente.

2.4.2. Filtrado de clutter terrestre

En los radares meteorológicos, el clutter terrestre representa una interferencia indeseada que oscurece la señal proveniente de los fenómenos de interés. Por lo general, la potencia asociada a esta interferencia es varios órdenes de magnitud superior respecto

de la señal de interés [3]. Como consecuencia de su fuerte intensidad, su presencia en la señal recibida sesga las estimaciones de los momentos espectrales del fenómeno meteorológico obtenidos mediante estimadores que no consideran esta interferencia. La señal proveniente del clutter terrestre posee una fuerte correlación [3], por lo que su densidad espectral de potencia es angosta y puede ser fácilmente identificada en la DEP total de la señal recibida por el radar.

La forma clásica de estimación de momentos espectrales en presencia de clutter terrestre consiste en aplicar un filtro pasa altos con una frecuencia de corte tal que elimine todas las componentes espectrales del clutter, para posteriormente aplicar un algoritmo de estimación de momentos, por ejemplo, PPP. El inconveniente de este método es que en el proceso se suelen eliminar componentes del espectro del fenómeno que se encuentran próximas a la velocidad Doppler media cero. Por ese motivo, desde hace dos décadas comenzaron a surgir algoritmos adaptivos que, además de filtrar el clutter terrestre, buscan reconstruir parte del espectro del fenómeno filtrado. A continuación se describirán algunos de los algoritmos existentes en la literatura para filtrado de clutter terrestre y estimación de momentos espectrales de manera conjunta.

2.4.3. Gaussian Model Adaptive Processing (GMAP)

GMAP [24] es un algoritmo adaptivo de filtrado de clutter, que debe su nombre a que considera el modelo gaussiano para las DEPs del fenómeno meteorológico y del clutter terrestre. En una primera instancia, crea máscaras para el clutter terrestre y el ruido, y a partir de ellas elimina las componentes espectrales del clutter. En la construcción de la máscara del clutter, además de la hipótesis de que su espectro posee forma gaussiana, GMAP se vale de que el ancho espectral del fenómeno σ_p es mayor que el ancho espectral del clutter σ_c , que además se supone conocido.

Debido a que, en general, el filtrado del clutter implica también el filtrado de parte de las componentes del fenómeno meteorológico, entonces, en una segunda etapa, realiza un procedimiento iterativo en el que estima los momentos espectrales del fenómeno meteorológico y reconstruye su DEP. Este proceso se repite hasta que se satisface un determinado criterio de convergencia.

Una de las ventajas de GMAP es que opera en el dominio de las frecuencias, lo cual involucra la DFT siendo eficiente su cálculo a partir de la transformada rápida de Fourier (FFT por sus siglas en inglés). Esta característica, lo hace atractivo al momento de su implementación, debido a que posee un costo computacional bajo. A continuación se describen los pasos del algoritmo y se acompaña la explicación con un ejemplo ilustrativo.

1. Ventaneo y estimación de la DEP

Cada CPI a procesar posee un número pequeño de muestras IQ y, además, la potencia del clutter terrestre puede ser varios órdenes de magnitud mayor a la potencia del fenómeno meteorológico. En estas condiciones, los lóbulos laterales debidos al espectro del clutter, que se producen al evaluar la DFT como consecuencia del truncado de la secuencia, enmascaran el espectro del fenómeno. Con el objetivo de mitigar los efectos de los lóbulos laterales, se emplean ventanas de modo de separar los espectros del clutter y del fenómeno. Inicialmente, GMAP propone aplicar una ventana de Hamming a los datos IQ y estimar la DEP usando periodograma de Welch [53].

A modo de ejemplo, la Figura 2.7 muestra una DEP estimada, obtenida a partir de $M = 64$ muestras de datos IQ sintéticos, a las que se les aplicó una ventana de Hamming. La señal generada se compone de clutter, fenómeno meteorológico y ruido, cada cual con su modelo correspondiente. La relación potencia de clutter a potencia de señal (CSR de sus siglas en inglés) es de 20 dB, la relación potencia de señal a potencia de ruido (SNR de sus siglas en inglés) es de 20 dB, $v_p = 0$ m/s, $\sigma_p = 2$ m/s, $f_c = 5,6$ GHz, $T_u = 1$ ms y $\sigma_c = 0,25$ m/s. En la figura se indican las diferentes componentes de la DEP: fenómeno, clutter y ruido.

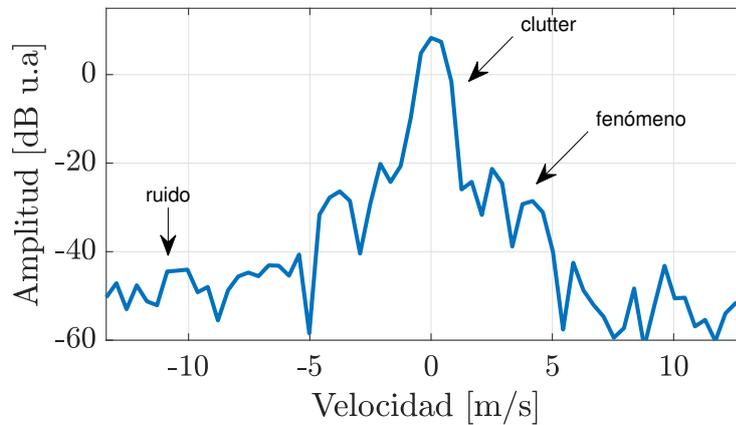


Figura 2.7: DEP de la señal sintética, estimada con ventana de Hamming.

2. Estimación de la potencia de ruido

Para bajos valores de SNR, se debe restar la contribución del ruido a la hora de estimar los momentos espectrales, en particular, para la potencia y el ancho del espectro del fenómeno. Por otro lado, debido a que en GMAP el clutter se elimina a partir de la DEP usando una máscara, es necesario conocer el nivel de ruido, para de esta forma identificar las componentes espectrales del clutter. Existen varios algoritmos de estimación de potencia de ruido. En esta tesis se adopta el presentado en [54], en el cual, a partir de la DEP de la señal se estima el nivel y la potencia de ruido. El método consiste en ir eliminando de la DEP, mediante

un proceso iterativo, aquellas componentes espectrales por encima de un cierto margen hasta lograr una DEP que se corresponda a un espectro plano. Para ello, se definen varios parámetros, los cuales hacen uso de las propiedades físicas del ruido blanco gaussiano, con el objetivo de poder establecer criterios para detener el ciclo iterativo. Finalmente, se reportan el nivel y la potencia de ruido. En la Figura 2.8 se muestra la DEP y el nivel de ruido para la situación simulada.

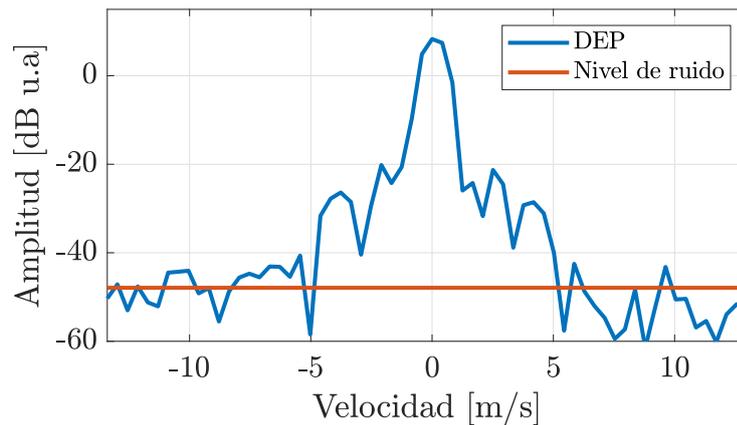


Figura 2.8: DEP de la señal sintética y la respectiva estimación del nivel de ruido.

3. Construcción de máscara y eliminación del clutter

Haciendo uso del modelo gaussiano para la forma de la DEP del clutter se construye una máscara. Se supone que la velocidad Doppler media del clutter es cero y, además, su ancho espectral es conocido, ya que es una hipótesis del método, como se destacó al comienzo de esta sección. Por lo tanto, solo es necesario calcular su potencia, la que se estima utilizando los tres puntos centrales del espectro, alrededor de la velocidad Doppler cero. Finalmente, se procede a construir la máscara, evaluando la función gaussiana, con los momentos indicados, en los valores de frecuencia correspondiente.

La máscara delimita la región del espectro que se supone que contiene componentes del espectro del clutter terrestre. Con esta idea, se seleccionan todos los puntos de la DEP que quedan dentro de la máscara y se los elimina.

Continuando con el ejemplo, la Figura 2.9 muestra la DEP de los datos IQ simulados, junto con la máscara de clutter superpuesta.

4. Estimación de momentos y reconstrucción del espectro

En el proceso de filtrado de clutter existe la posibilidad que sean removidas componentes del espectro del fenómeno meteorológico cercanas a la velocidad Doppler cero. Por este motivo, GMAP contempla una estrategia para extrapolar los valo-

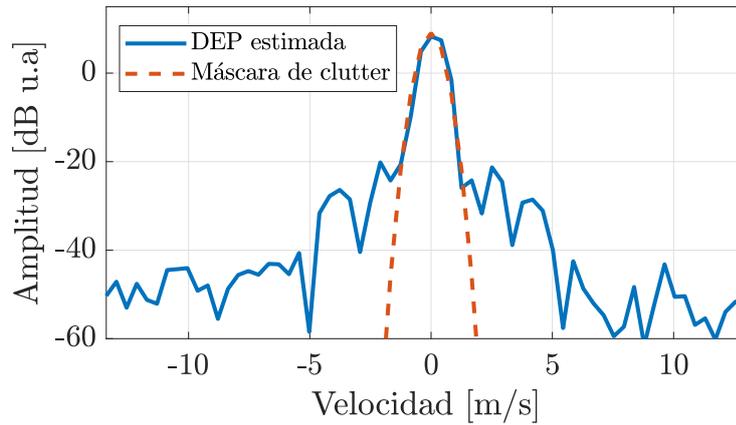


Figura 2.9: DEP de la señal sintética y la respectiva máscara para la eliminación del clutter.

res que poseían las muestras eliminadas del espectro previo a ser contaminadas con clutter.

Para ello, una vez eliminadas las componentes de clutter, se realiza una primera estimación de los momentos espectrales empleando PPP. Esto implica contar con una estimación de la autocorrelación en los lags 0 y T_u , tal como se detalló en la Sección 2.4.1. Valiéndose del teorema de Wiener-Khinchin, la autocorrelación se obtiene como la transformada discreta inversa de Fourier (IDFT por sus siglas en inglés) de la DEP filtrada.

Con los momentos espectrales estimados, se reconstruyen las muestras del espectro que fueron removidas, haciendo uso del modelo gaussiano. El mecanismo consiste en evaluar la ecuación (2.12), siendo sus momentos los estimados, en los valores de velocidad correspondientes a las muestras eliminadas y reemplazarlos en el espectro filtrado.

Este proceso se repite de forma iterativa, es decir, se vuelven a estimar los momentos espectrales y se vuelve a reconstruir la DEP, de la manera detallada. El procedimiento iterativo se detiene cuando la diferencia de estimaciones de potencias consecutivas de fenómeno \hat{p}_p no supere los 0.2 dB y la diferencia de estimaciones consecutivas de velocidad Doppler media \hat{v}_p no supere 0.5% de v_a .

En la Figura 2.10 se presentan los resultados del proceso iterativo de reconstrucción de la DEP del fenómeno meteorológico, para el mismo ejemplo con el que se viene trabajando en los pasos anteriores.

5. Optimización de la ventana empleada

Es importante mencionar que la estimación de los momentos espectrales se ve afectada debido al derrame (en inglés, *leakage*) producido en la estimación de la DEP como consecuencia del truncado de la secuencia en el dominio del tiempo.

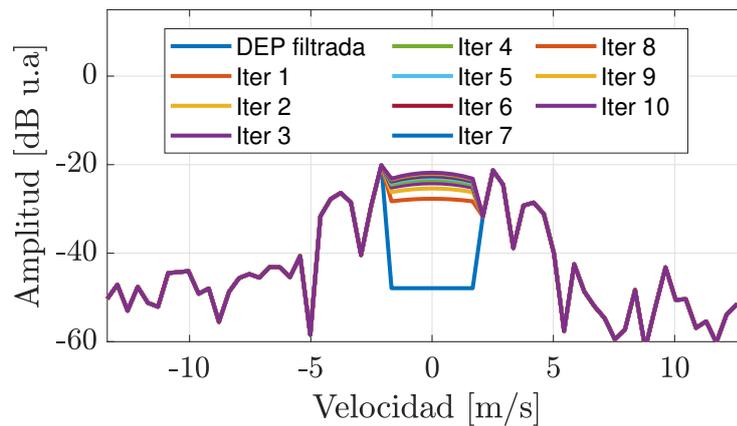


Figura 2.10: Proceso iterativo de reconstrucción de la DEP.

Este efecto tiene mayor influencia cuando la intensidad del clutter es alta y puede ser reducido con la utilización de la ventana adecuada al momento de estimar el espectro, a costa de ensanchar el lóbulo principal del espectro del clutter.

En una primera ejecución GMAP propone utilizar una ventana de Hamming, luego se evalúa la CSR obtenida, y en función del valor que tome se repiten los pasos 1 a 4 del proceso anterior variando la ventana empleada en la estimación de la DEP. Específicamente, una vez obtenida la CSR los pasos a seguir son los siguientes:

- Si $CSR > 40$ dB se repiten los pasos del 1 a 4 usando una ventana de Blackman y se toman como válidos los resultados obtenidos con la ventana de Blackman.
- Si $CSR > 20$ dB se repiten los pasos 1 a 4 usando ventana de Blackman y se estima la nueva CSR. Cuando el nuevo valor de $CSR > 25$ dB se toman como válidos los resultados obtenidos con la ventana de Blackman. Caso contrario, se toman como válidos los resultados iniciales obtenidos empleando la ventana de Hamming.
- Si $CSR > 2.5$ dB se realizan los pasos 1 a 4 usando ventana rectangular y se estima la nueva CSR. Cuando la nueva $CSR < 1$ dB, entonces se toman como válidos los resultados obtenidos con la ventana rectangular. Caso contrario, se toman como válidos los resultados iniciales obtenidos empleando la ventana de Hamming.

La Figura 2.11 muestra en un diagram de bloques la lógica de decisión en el proceso de optimización de la ventana usada en GMAP.

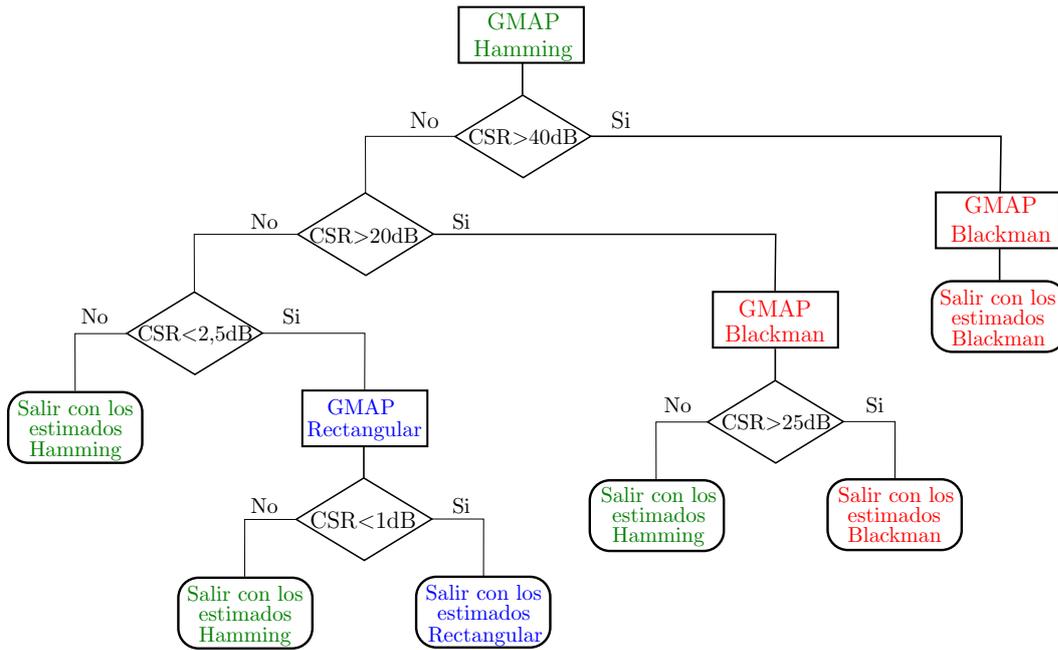


Figura 2.11: Lógica de decisión para el proceso de optimización de la ventana empleada.

2.4.4. GMAP in Time Domain (GMAP-TD)

Una de las ventajas de GMAP es su eficiencia desde el punto de vista del costo computacional, como consecuencia de que opera en el dominio de la frecuencia. Sin embargo, el truncado de las secuencias a un número pequeño de muestras en el dominio de la frecuencia produce lo que se conoce como efecto de derrame, que consiste en que los lóbulos laterales de las ventanas empleadas contaminan las componentes espectrales adyacentes a las del lóbulo central del espectro. Esta situación es habitual en las aplicaciones de radar meteorológico y, en especial, es particularmente crítica para el clutter, debido a que su intensidad es significativa, llevando, en ocasiones, al enmascaramiento del espectro del fenómeno meteorológico.

Con la motivación de lidiar con el efecto de derrame, existe una versión de GMAP, conocida como *GMAP in Time Domain* (GMAP-TD), que opera en el dominio del tiempo [25]. Al igual que GMAP, es un algoritmo adaptivo para la mitigación de clutter terrestre y estimación de los momentos espectrales.

Las hipótesis sobre las que se fundamenta GMAP-TD son las mismas que las de GMAP, es decir, considera que el modelo gaussiano tanto para la DEP del clutter, $S_c(v)$, como para la DEP del fenómeno, $S_p(v)$, el ruido se modela como blanco, y el ancho espectral del clutter es aproximadamente conocido

Teniendo en cuenta estas suposiciones, haciendo uso del teorema de *Wiener – Khinchin* es posible escribir la autocorrelación de la señal recibida, $R(\tau)$, de la siguiente

manera

$$R(\tau) = R_c(\tau) + R_p(\tau) + R_n(\tau) \quad (2.21a)$$

$$R_c(\tau) = p_c e^{-\frac{8\pi^2 \sigma_c^2 \tau^2}{\lambda^2}} \quad (2.21b)$$

$$R_p(\tau) = p_p e^{-\frac{8\pi^2 \sigma_p^2 \tau^2}{\lambda^2}} e^{-\frac{j4\pi v_p \tau}{\lambda}} \quad (2.21c)$$

$$R_n(\tau) = \sigma_n^2 \delta(\tau), \quad (2.21d)$$

donde los subíndices c , p y n refieren al clutter, fenómeno y ruido, respectivamente, σ_n^2 es la potencia media del ruido y $\delta(t)$ es la delta de Dirac.

Se denota como $\mathbf{x} \in \mathbb{C}^{M \times 1}$ al vector de muestras IQ a la salida del demodulador en cuadratura, correspondiente a determinado rango y a un dado CPI. Luego, su matriz de autocorrelación está dada por

$$\mathbf{R}_x = E[\mathbf{x}\mathbf{x}^H] \quad (2.22)$$

$$= \mathbf{R}_c + \mathbf{R}_p + \mathbf{R}_n, \quad (2.23)$$

donde $E[\cdot]$ es el operador esperanza; H representa la operación de transposición hermítica; y \mathbf{R}_c , \mathbf{R}_p y \mathbf{R}_n son las matrices de autocorrelación del clutter, del fenómeno y del ruido, respectivamente. Cuando el radar opera con PRI uniforme T_u , directamente de la ecuación (2.22), se obtiene que los elementos \mathbf{R}_x son de la forma

$$\mathbf{R}_x = \begin{pmatrix} R(0) & R(-T_u) & R(-2T_u) & \cdots & R(-(M-1)T_u) \\ R(T_u) & R(0) & R(-T_u) & \cdots & R(-(M-2)T_u) \\ R(2T_u) & R(T_u) & R(0) & \cdots & R(-(M-3)T_u) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ R((M-1)T_u) & R((M-2)T_u) & R((M-3)T_u) & \cdots & R(0) \end{pmatrix}. \quad (2.24)$$

La idea es encontrar un filtro representado por una matriz \mathbf{A} , de dimensiones $M \times M$, que elimine el clutter terrestre del vector de datos \mathbf{x} . Denotando como $\mathbf{y} = \mathbf{A}\mathbf{x}$ al vector a la salida del filtro representado por \mathbf{A} , entonces la matriz de autocorrelación de \mathbf{y} está dada por

$$\begin{aligned} \mathbf{R}_y &= E[\mathbf{y}\mathbf{y}^H] \\ &= E[(\mathbf{A}\mathbf{x})(\mathbf{A}\mathbf{x})^H] \\ &= \mathbf{A}\mathbf{R}_x\mathbf{A}^H \\ &= \mathbf{A}(\mathbf{R}_c + \sigma_n^2 \mathbf{I}_M)\mathbf{A}^H + \mathbf{A}\mathbf{R}_p\mathbf{A}^H, \end{aligned} \quad (2.25)$$

donde \mathbf{I}_M representa la matriz diagonal unidad, de dimensiones $M \times M$.

Notar que el primer término de la ecuación (2.25) representa la respuesta del filtro a las componente de clutter y ruido, mientras que el segundo término representa la respuesta del filtro a la componente del fenómeno meteorológico.

En la deducción de una expresión para la matriz \mathbf{A} , sólo se tiene en cuenta el primer término de la ecuación (2.25), lo cual es equivalente a suponer que no existen presentes ecos meteorológicos en la señal recibida, es decir, $\mathbf{R}_p = \mathbf{0}$. En estas condiciones, se requiere que el vector de salida del filtro, tenga una matriz de autocorrelación similar a la de un proceso de ruido blanco, lo cual se describe matemáticamente como

$$\mathbf{R}_y = \mathbf{A}(\mathbf{R}_c + \sigma_N^2 \mathbf{I}_M) \mathbf{A}^H \approx \sigma_N^2 \mathbf{I}_M. \quad (2.26)$$

La interpretación de la ecuación (2.26), es que se busca que el filtro sea capaz de atenuar la componente de clutter a niveles comparables con los del ruido.

La ecuación (2.26) permite hallar una expresión para el filtro \mathbf{A} . En particular, en [25] se propone como posible solución

$$\mathbf{A} = \left(\frac{\mathbf{R}_c}{\sigma_N^2} + \mathbf{I}_M \right)^{-1/2}, \quad (2.27)$$

donde la potencia $-1/2$ denota la raíz cuadrada de una matriz inversa.

La solución de la ecuación (2.27) siempre existe, debido a que la matriz de autocorrelación \mathbf{R}_c es hermítica definida semipositiva, al igual que la matriz \mathbf{A} . Es importante notar que para construir el filtro \mathbf{A} es necesario conocer los parámetros del clutter σ_c , p_c y la potencia de ruido. Se recomienda hacer uso de las mismas consideraciones que en GMAP con el objetivo de obtener las estimaciones de estos parámetros.

Con respecto a la autocorrelación de la componente de señal debido al fenómeno meteorológico, es deseable que al aplicar el filtro la misma se modifique lo menos posible. Sin embargo, del segundo término de la suma en la ecuación (2.25) se observa que algún efecto tendrá sobre la misma. Independientemente de que este algoritmo opere en el dominio del tiempo, se puede analizar su efecto de manera análoga en el dominio de la frecuencia. Con este enfoque, si la velocidad del fenómeno es cercana a cero, se superponen los espectros de este último y del clutter. Por lo que, este filtro buscará “blanquear” el espectro del clutter afectando en el proceso el espectro del fenómeno. Efecto análogo al que se produce en GMAP.

En pos de mitigar ese problema, se propone un procedimiento iterativo con el objetivo de reconstruir la parte de \mathbf{R}_p filtrada. Este procedimiento también es análogo a lo que se hace en GMAP, con la diferencia de que opera sobre la autocorrelación. Valiéndose de la autocorrelación estimada a la salida del filtro, $\hat{\mathbf{R}}_y = \mathbf{A} \mathbf{x} \mathbf{x}^H \mathbf{A}^H$, se estiman los momentos espectrales, \hat{p}_p , \hat{v}_p y $\hat{\sigma}_p$, por medio de PPP. Haciendo uso de la hipótesis de que la forma de la autocorrelación del fenómeno es gaussiana, se obtiene

una expresión para la matriz de autocorrelación del fenómeno, \mathbf{R}_p . Por último, se calcula la diferencia entre las matrices $\mathbf{A}\hat{\mathbf{R}}_p\mathbf{A}^H$ y $\text{textbf}R_p$. Notar que esta diferencia $\mathbf{A}\mathbf{R}_p\mathbf{A}^H - \hat{\mathbf{R}}_p$ es una aproximación de la “porción” de la componente del fenómeno meteorológico que $\hat{\mathbf{R}}_y$ perdió junto con la componente de clutter al haber aplicado el filtro representado por la matriz \mathbf{A} . Por este motivo, la diferencia $\mathbf{A}\mathbf{R}_p\mathbf{A}^H - \mathbf{R}_p$ se le suma a la matriz $\hat{\mathbf{R}}_y$, para su actualización.

Este procedimiento se repite iterativamente hasta que se llega a un criterio de convergencia. En la Figura 2.12, se presenta una representación esquemática del proceso iterativo de GMAP-TD. Haciendo una analogía con GMAP, esto es equivalente lo que se hace para reconstruir la región del espectro del fenómeno removida en el filtrado del clutter, sin embargo, en este caso se reconstruye la autocorrelación en lugar de la DEP. La recomendación es detener el proceso iterativo cuando las diferencias de estimaciones consecutivas de potencia y velocidad estén acotadas por un cierto valor. En el caso de la potencia se usa como cota 0.1 dB y para la velocidad 0.5 % de v_a . Cuando se cumple dicho criterio de parada se reportan los valores estimados de los momentos espectrales.

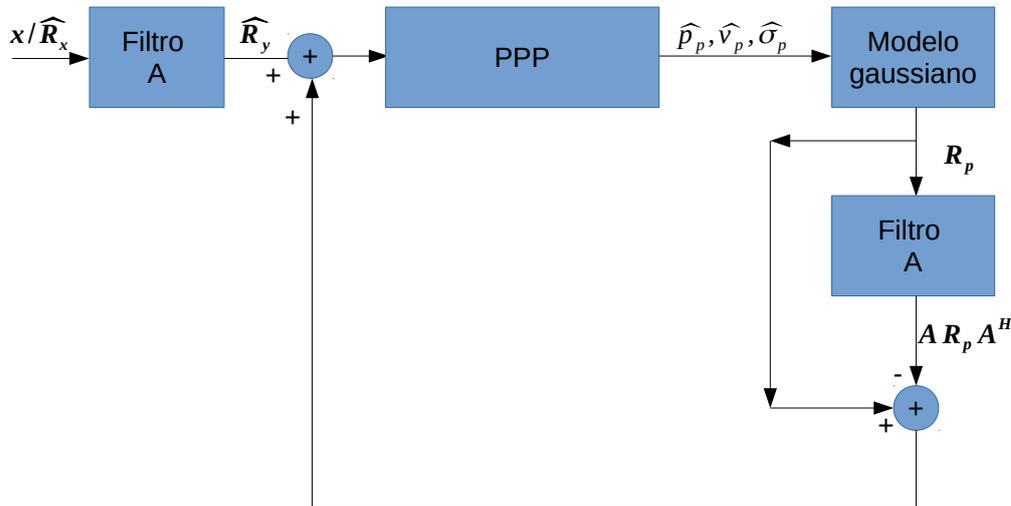


Figura 2.12: Esquema del proceso iterativo de GMAP-TD.

2.5. Procesamiento Doppler para modo *staggered*

Como se describió en la Sección 2.2.3, en la práctica los radares meteorológicos sufren de ambigüedad en rango cuando se utilizan PRI pequeñas para incrementar el rango Doppler no ambiguo. Las técnicas de alternar las PRIs, *staggered* PRIs, permiten incrementar la velocidad Doppler no ambigua sin degradar el rango máximo no ambiguo

[17]. Si bien existen diferentes combinaciones de PRIs, en general se emplea el sistema que utiliza dos PRIs, donde el intervalo entre pulsos alterna entre las PRIs T_1 y T_2 . En esta sección se extienden las ideas de PPP al modo de operación *staggered* que emplea dos PRIs y se estudia la versión *staggered* del algoritmo de filtrado de clutter terrestre GMAP-TD.

2.5.1. Staggered PPP

En la Figura 2.13 se representa esquemáticamente la secuencia de datos muestreada a la salida del receptor para la dimensión tiempo lento, cuando se emplea la estrategia de operación *staggered* que alterna entre las dos PRIs, T_1 y T_2 , de forma periódica. Como se observa en el esquema, la secuencia resultante se encuentra muestreada de forma no uniforme.

Para deducir los estimadores de los momentos espectrales, se considera que la señal sólo se compone de contribuciones del fenómeno meteorológico más ruido blanco. Luego, al igual que cuando la PRI es uniforme, la potencia del fenómeno meteorológico se estima a partir de la autocorrelación $\hat{R}(\tau)$ de la señal evaluada en cero, descontando la potencia del ruido \hat{P}_n

$$\hat{p}_p = \hat{R}(0) - \hat{P}_n. \quad (2.28)$$

Bajo la hipótesis de que la DEP del fenómeno meteorológico posee simetría par con respecto a su velocidad Doppler media, es posible obtener un estimador de dicha velocidad Doppler media a partir de las estimaciones de la autocorrelación $\hat{R}(\tau)$ en los lags T_1 y T_2 , $\hat{R}(T_1)$ y $\hat{R}(T_2)$, respectivamente, el cual está dado por

$$\hat{v}_p = \frac{\lambda}{4\pi(T_2 - T_1)} \arg \left(\frac{\hat{R}(T_1)}{\hat{R}(T_2)} \right). \quad (2.29)$$

A partir de la ecuación (2.29), la velocidad máxima no ambigua se obtiene cuando $\arg \left(\frac{\hat{R}(T_1)}{\hat{R}(T_2)} \right) = \pm\pi$ y su valor resulta

$$v_a = \pm \frac{\lambda}{4(T_2 - T_1)}. \quad (2.30)$$

De la ecuación (2.30) se observa que la velocidad máxima no ambigua depende de la diferencia $T_2 - T_1$. Por lo tanto, al disminuir la diferencia entre las PRIs se logran valores de v_a mayores. Sin embargo, en la práctica no es posible reducir esa diferencia tanto como se desearía. Se puede demostrar que a medida que la relación $\kappa = T_1/T_2$ se aproxima a uno, el error en la estimación de la velocidad se incrementa [17]. Por este motivo, la elección de $3T_1 = 2T_2$, es en general la opción elegida para lidiar con la relación de compromiso entre el valor de v_a y el error de estimación en la velocidad

Doppler media. A este modo de operación se lo denomina *staggered 2/3* y es el que se empleará a lo largo de la tesis.

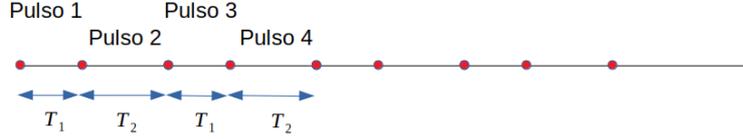


Figura 2.13: Muestreo *staggered* usando dos PRI.

Como ocurre en PPP con PRI uniforme, para hallar el estimador del ancho del espectro es necesario hacer uso del modelo gaussiano para la DEP del fenómeno meteorológico. En estas condiciones, el ancho del espectro σ_p puede ser estimado a partir del cociente de estimados $\hat{R}(T_1)$ y $\hat{R}(T_2)$ como

$$\hat{\sigma}_p = \frac{\lambda}{2\pi\sqrt{2(T_2^2 - T_1^2)}} \sqrt{\ln\left(\frac{|\hat{R}(T_1)|}{|\hat{R}(T_2)|}\right)}. \quad (2.31)$$

Los estimadores de velocidad y ancho espectral dados por las ecuaciones (2.29) y (2.31), respectivamente, en general presentan errores de estimación altos. Esto es consecuencia de la propagación de errores del cociente que involucra los estimados de la autocorrelación en los lags T_1 y T_2 . Sumado a lo anterior, cuanto mayor sea el lag de la autocorrelación, menor es el número de muestras disponibles para realizar la estimación, lo que degrada aún más el desempeño. Por este motivo, han surgido variantes de estimadores que evitan dicho cociente, o bien emplean la autocorrelación en el lag 0.

En estas condiciones, para el ancho espectral, en función de la SNR presente, una propuesta consiste en utilizar alguno de los siguientes estimadores [17]

$$\hat{\sigma}_p = \frac{\lambda}{2\pi T_1} \sqrt{\frac{1}{2} \ln\left(\frac{\hat{p}_p}{|\hat{R}(T_1)|}\right)} \quad (2.32a)$$

$$\hat{\sigma}_p = \frac{\lambda}{2\pi T_2} \sqrt{\frac{1}{2} \ln\left(\frac{\hat{p}_p}{|\hat{R}(T_2)|}\right)}. \quad (2.32b)$$

Específicamente, se sugiere usar la ecuación (2.32a) para valores de SNR por encima de los 20 dB y la ecuación (2.32b) para valores de SNR por debajo de 20 dB. La elección anterior se debe a que para valores bajos de SNR la estimación de $R(T_2)$ presenta menor error que la estimación de $R(T_1)$. Se denominará *staggered PPP* (SPPP) al conjunto

de estimadores de los momentos espectrales dados por las ecuaciones (2.28), (2.29) y (2.32).

2.5.2. Método de desambiguación de velocidad

El método de desambiguación (DA de sus siglas en inglés) de la velocidad [29] es un método de estimación de la velocidad Doppler media que logra un error de estimación menor al del estimador dado por (2.29), evitando el cociente de los estimados de la correlación. El mismo, utiliza dos estimados de la autocorrelación $\hat{R}(\tau)$, evaluada en los instantes T_1 , $\hat{R}(T_1)$ y T_2 , $\hat{R}(T_2)$ para obtener dos estimaciones de la velocidad Doppler media mediante las ecuaciones

$$\hat{v}_{p1} = -\frac{\lambda}{4\pi T_1} \arg(\hat{R}(T_1)) \quad (2.33a)$$

$$\hat{v}_{p2} = -\frac{\lambda}{4\pi T_2} \arg(\hat{R}(T_2)), \quad (2.33b)$$

las cuales en el caso más general, serán estimaciones ambiguas de la velocidad, ya que los valores de velocidades no ambiguas asociadas a T_1 y T_2 son pequeñas.

Sin embargo, suponiendo que sólo existe ambigüedad de primer orden (esto quiere decir que se considera que la velocidad Doppler real del fenómeno se encuentra en el rango no ambiguo o bien en alguno de los intervalos de velocidad adyacentes al rango no ambiguo), entonces existen tres posibles valores de velocidad que pueden dar como resultado los estimadores dados por (2.33). Para la primera estimación se tiene el conjunto de velocidades \hat{v}_{p1} , $\hat{v}_{p1} + 2v_{a1}$ y $\hat{v}_{p1} - 2v_{a1}$, donde v_{a1} representa la velocidad máxima no ambigua asociada a la PRI T_1 . Análogamente, para la segunda estimación se tiene el conjunto de velocidades \hat{v}_{p2} , $\hat{v}_{p2} + 2v_{a2}$ y $\hat{v}_{p2} - 2v_{a2}$, donde v_{a2} representa la velocidad máxima no ambigua asociada a la PRI T_2 .

En las condiciones planteadas, sólo existe un valor común en los dos conjuntos de velocidades, el cual corresponde a la solución correcta. Es importante destacar que de los estimados obtenidos el que se obtiene empleando solo la estimación $\hat{R}(T_1)$ posee un error de estimación menor, y significativamente menor que al emplear el estimador SPPP dado por (2.29). Por este motivo, el algoritmo DA propone elegir los dos valores que se encuentren más cercano en ambos conjuntos y posteriormente reportar como estimación de velocidad la obtenida usando el primer conjunto de valores, teniendo en cuenta que la estimación usando T_1 tiene menor varianza que usando T_2 . Se puede decir que \hat{v}_{p1} se emplea para determinar el valor de velocidad estimada y que \hat{v}_{p2} se usa para desambiguarlo.

2.5.3. GMAP-TD en modo *staggered*

Una de las ventajas de GMAP-TD sobre GMAP es que el mismo puede ser extendido, fácilmente, para ser utilizado con una señal obtenida en el modo de operación *staggered* [25]. El método puede ser utilizado para cualquier relación entre T_1 y T_2 . Sin embargo, sin pérdida de generalidad, en este trabajo se abordará el modo de operación *staggered* 2/3.

Considerando el vector \mathbf{x} , de muestras complejas correspondientes a los datos IQ, de dimensiones $M \times 1$, correspondiente a un rango determinado y un dado CPI. Teniendo en cuenta que la media de \mathbf{x} es nula, a partir de su definición ($\mathbb{E}[\mathbf{x}\mathbf{x}^H]$), se puede demostrar que la matriz de autocorrelación de \mathbf{x} está dada por

$$\mathbf{R}_x = \begin{pmatrix} R(0) & R(-T_1) & R(-T_1-T_2) & \cdots & R(-\frac{M}{2}(T_1+T_2)) \\ R(T_1) & R(0) & R(-T_2) & \cdots & R(-\frac{M}{2}(T_1+T_2)-T_1) \\ R(T_1+T_2) & R(T_2) & R(0) & \cdots & R(-\frac{M-2}{2}(T_1+T_2)) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ R(\frac{M}{2}(T_1+T_2)) & R(\frac{M}{2}(T_1+T_2)+T_1) & R(\frac{M-2}{2}(T_1+T_2)) & \cdots & R(0) \end{pmatrix}. \quad (2.34)$$

Las hipótesis sobre las que se sustenta este método de filtrado de clutter terrestre son las mismas que para el caso de PRI uniforme. Sin embargo, existe una serie de consideraciones adicionales, que deben ser tenidas en cuenta al momento de realizar la extensión a PRI alternadas.

La primera consideración está relacionada con las estimaciones de potencia de clutter y potencia de ruido. Debido a que la señal *staggered* no está muestreada de forma uniforme, no tiene sentido estimar su DEP aplicando directamente la DFT de la serie temporal, porque los instantes de tiempo de cada exponencial no se corresponden con los instantes de las muestras de la señal. Por este motivo, sobre la base de la secuencia de datos muestreada de forma no uniforme, se construye una nueva secuencia de datos muestreada uniformemente, con período de muestreo $T_u = T_2 - T_1$, en la que se insertan ceros en los instantes donde no existen muestras de señal disponible. Para esto último, es necesario que $T_1 = n_1 T_u$ y $T_2 = n_2 T_u$, con n_1, n_2 naturales.

A esta nueva secuencia se le puede aplicar la DFT para evaluar su DEP, pero posee en total cinco réplicas del espectro de la señal original, como consecuencia de la interpolación con ceros. Es decir, el espectro resultante incluye la réplica original del clutter y del fenómeno centradas en la velocidad 0 y v_p , respectivamente; y cuatro réplicas más de clutter y del fenómeno en posiciones de velocidad que dependen de la relación entre T_1 y T_2 [5]. En particular, para *staggered* 2/3, las réplicas adicionales del espectro del clutter se ubican en $\pm 0,4v_a$ y $\pm 0,8v_a$, mientras que las réplicas adicionales del espectro del fenómeno meteorológico se ubican en las velocidades $v_p \pm 0,4v_a$, $v_p \pm 0,8v_a$.

Las estimaciones de la potencia de clutter y potencia de ruido se realizan siguiendo el procesamiento propuesto por GMAP, pero sobre la DEP estimada con el proceso descrito.

La segunda consideración respecta a la construcción del filtro \mathbf{A} . En principio, se puede pensar en diseñar \mathbf{A} aplicando, directamente, la ecuación (2.27) empleando la expresión de la autocorrelación dada por (2.34). Sin embargo, esta estrategia de diseño no es recomendable, porque además del *notch* deseado alrededor de la frecuencia 0, aparecen notches indeseados en otras posiciones de frecuencia [55], ver Figura 2.14(a). Esos notches indeseados, filtran por demás el espectro del fenómeno meteorológico introduciendo errores significativos en la estimación de momentos espectrales. En el caso particular *staggered* 2/3, estos notches aparecen en los mismos valores de frecuencia que las réplicas de clutter, pero con distintas magnitudes. Por este motivo, se propone realizar una modificación del filtro, con el requerimiento de que \mathbf{A}_{mod} posea una respuesta en frecuencia de igual magnitud para todos los notches, ver Figura 2.14(b). Una forma de cumplir con este propósito, consiste en calcular la matriz \mathbf{A}_{mod} de la siguiente manera

$$\mathbf{A}_{mod} = \left(\frac{\mathbf{R}_{mod}}{\sigma_N^2} + I_M \right)^{-1/2} \quad (2.35a)$$

$$\mathbf{R}_{mod} = \mathbf{R}_c + \mathbf{R}_{c,\pm 0.4} + \mathbf{R}_{c,\pm 0.8}, \quad (2.35b)$$

$$(2.35c)$$

donde las matrices $\mathbf{R}_{c,\pm 0.4}$ y $\mathbf{R}_{c,\pm 0.8}$ son versiones desplazadas de \mathbf{R}_c . Se construyen con la misma estructura que presenta la ecuación (2.34) para \mathbf{R}_x , pero con sus elementos dados por

$$R_c(\tau) = p_c e^{-\frac{8\pi^2 \sigma_c^2 \tau^2}{\lambda^2}} \quad (2.36a)$$

$$R_{c,\pm 0.4}(\tau) = p_c e^{-\frac{8\pi^2 \sigma_c^2 \tau^2}{\lambda^2}} e^{-\frac{j(\pm)0.4\pi\tau}{T_u}} \quad (2.36b)$$

$$R_{c,\pm 0.8}(\tau) = p_c e^{-\frac{8\pi^2 \sigma_c^2 \tau^2}{\lambda^2}} e^{-\frac{j(\pm)0.8\pi\tau}{T_u}} \quad (2.36c)$$

Teniendo en cuenta estas consideraciones, el procesamiento de secuencias *staggered* usando GMAP-TD es análogo al procesamiento para secuencias obtenidas con PRT uniforme [25].

2.6. Datos de radar meteorológico

Los algoritmos de procesamiento propuestos en esta tesis serán validados usando datos sintéticos y datos reales. La generación de datos sintéticos es una herramien-

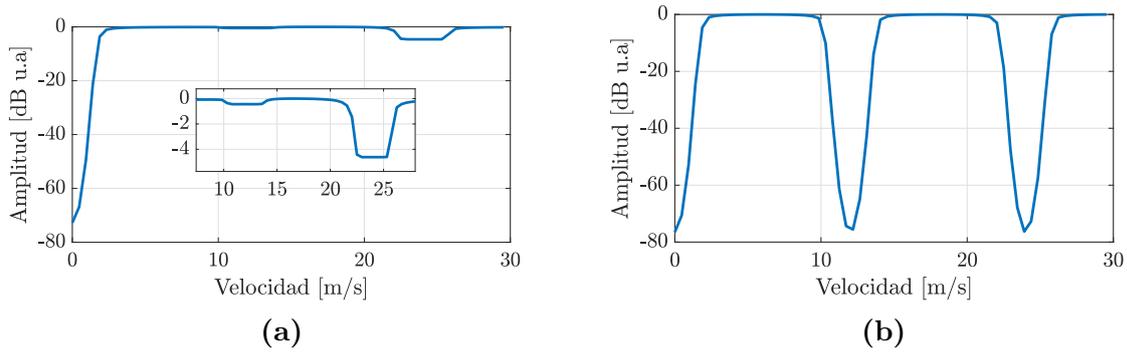


Figura 2.14: Respuesta en potencia del filtro para versión *staggered 2/3* de GMAP-TD con una relación de clutter-potencia de ruido $CNR = 60$ dB, y $\sigma_c = 0,28$ m/s. (a) Utilizando \mathbf{A} , además se exhibe una ampliación para ver en detalle la profundidad de los notches. (b) Utilizando \mathbf{A}_{mod} .

ta fundamental en muchas áreas de las ciencias e ingenierías, que permite evaluar el desempeño de algoritmos en distintos escenarios a partir de experimentos controlados. En el marco de esta tesis, se utilizan las ideas del trabajo [56] con el objetivo de generar datos sintéticos que cumplan con las propiedades de la señal meteorológica en la dimensión tiempo lento, en especial se generan datos con distribución de probabilidad gaussiana, que satisfacen el modelo de DEP gaussiana para el clutter y para el fenómeno meteorológico, y de DEP plana para el ruido. Cabe destacar que cuando se haga mención a una realización de datos sintéticos, se está haciendo referencia a un vector de datos complejos IQ $V_r(m) = I(m) + jQ(m)$ de longitud M , el cual se corresponde a muestras de la señal de un CPI para un determinado rango. Asimismo, la generación de datos sintéticos para el modo de operación *staggered* se realiza a partir del muestreo no uniforme de una secuencia generada con muestreo uniforme a una tasa mayor.

Para el procesamiento de los datos reales se utilizan mediciones adquiridas por los radares argentinos RMA, diseñados y fabricados por la empresa INVAP. Los mismos son radares meteorológicos polarimétricos que operan en banda C. Si bien estos radares poseen la capacidad de explotar la polarimetría de la señal, el trabajo propuesto tiene por objetivo el procesamiento Doppler de la señal, por lo que se utiliza únicamente el canal correspondiente a la polarización horizontal tanto para la onda transmitida como para la onda recibida, lo cual se suele denotar como polarización HH. A lo largo de la tesis se emplean mediciones correspondientes a dos radares RMA. Por un lado, se utilizan datos adquiridos con el radar RMA-12, emplazado en el aeropuerto de la ciudad de San Carlos de Bariloche, correspondientes al 1° de febrero de 2020. Se utilizan varios barridos completos separados por pocos minutos, que abarcan el modo convencional de operación y el modo de operación *staggered 2/3*. El fenómeno meteorológico que registran las mediciones es lluvia. Todas las adquisiciones se corresponden a un ángulo de elevación de $1,7^\circ$, lo que asegura la presencia de clutter terrestre por las característi-

cas del terreno. Por otro lado, se utilizan mediciones registradas por el radar RMA-11, ubicado en la ciudad de Termas de Río Hondo, correspondientes a una tormenta del 2 de diciembre de 2020. Se utiliza un único barrido correspondiente al modo convencional de operación, con un ángulo de elevación de $0,5^\circ$, asegurando la presencia de clutter terrestre.

2.7. Introducción al machine learning y deep learning

El aprendizaje por computador (en inglés, machine learning, ML) es una rama de la inteligencia artificial (IA por sus siglas en inglés), en la cual se desarrollan técnicas con el objetivo de que las computadoras aprendan a partir de los datos. Una de las posibles definiciones del concepto “aprender” es el siguiente [57]: “Se dice que un programa de computadora aprende de una experiencia E , con respecto a algunos tipos de tareas T y medida de desempeño P ; si el desempeño para las tareas T , medido usando P , mejora con la experiencia E ”. En este contexto algunos ejemplos de tareas T son: la clasificación de imágenes, detección de anomalías y la regresión. Para evaluar la habilidad del algoritmo de ML es necesario diseñar una medida cuantitativa del desempeño. Usualmente, la medida del desempeño P es específica para la tarea T . En el caso de la clasificación es común usar la medida de exactitud (en inglés, *accuracy*) del modelo. El *accuracy* es la proporción de ejemplos para los cuales el modelo produce la respuesta correcta. Por otro lado, la experiencia E está relacionada con la información disponible para que el modelo pueda aprender. Los algoritmos de ML se dividen en tres grupos: aprendizaje supervisado, aprendizaje no supervisado, y aprendizaje por refuerzo (en inglés *reinforcement learning*).

En el aprendizaje supervisado se cuenta con un conjunto de datos etiquetados (\mathbf{x}_n, y_n) , donde \mathbf{x}_n son las características (en inglés, *features*) e y_n son las etiquetas. De forma muy simplificada, el objetivo es encontrar la probabilidad condicional $p(y|\mathbf{x})$ [58]; es decir, dado \mathbf{x} poder determinar con la mayor probabilidad cuál es la etiqueta correspondiente y . El término supervisado surge de considerar que la etiqueta y la provee un maestro, el cual le dice al sistema de ML qué hacer. Es importante mencionar que en los algoritmos de ML se realiza la extracción de *features* a partir de los datos de entrenamiento. Estos datos están conformados por un subconjunto de los datos etiquetados. Por lo tanto, ML requiere de una etapa de procesamiento previa al entrenamiento que consiste en la identificación y extracción de las características deseadas. Por ejemplo, si el objetivo consiste en clasificar, usando imágenes, la variedad de flores dentro de una misma especie, parte de esas imágenes serán los datos de entrenamiento, y es necesario extraer los *features* de esas imágenes, los que podrían ser el largo y ancho de los pétalos

y de los sépalos. Cabe remarcar que la elección y extracción de los *features* no es trivial, y en muchas ocasiones es la parte más difícil a la hora de entrenar un modelo de ML.

En el aprendizaje no supervisado el modelo se ajusta a las observaciones (\mathbf{x}_n), no existe conocimiento a priori de la etiqueta de cada observación. Uno de los objetivos es encontrar la distribución de probabilidad de las observaciones $p(\mathbf{x})$ [58]. Entre los usos de este tipo de aprendizaje encontramos, el agrupamiento (en inglés, *clustering*) y la compresión de datos.

En el *reinforcement learning* no se usa explícitamente un conjunto de datos de entrenamiento, sino que, se define un agente (por ejemplo, un robot) que aprende a comportarse en un determinado ambiente a través de la toma de acciones y cuantificando el resultado de las mismas. Si el agente toma decisiones correctas recibe recompensas (en inglés, *rewards*), en caso contrario no las recibe. El objetivo es maximizar los rewards en función del tiempo.

Algunos de los algoritmos más populares de ML son: árboles de decisión (en inglés, *decision trees*), agrupamiento de K-medias (en inglés, *K-means clustering*), primeros K vecinos más cercanos (en inglés, *K-nearest neighbor*), máquina de soporte de vector (en inglés, *support vector machine*) [58]. El desafío central de machine learning, es lograr que el modelo entrenado se desempeñe bien usando nuevos datos (no empleados previamente durante el entrenamiento). La habilidad de desempeñarse bien sobre datos nuevos se denomina generalización. Típicamente, cuando se entrena un modelo de ML se tiene un conjunto de datos de entrenamiento. Sobre este conjunto se mide el error de entrenamiento y se minimiza. Lo que separa al ML de un problema de optimización es que, además, se pide que se minimice el error de generalización.

El aprendizaje profundo (en inglés, *deep learning*, DL) es una subcategoría del machine learning. Al igual que este último, deep learning se divide en tres grupos: supervisado, no supervisado, y por refuerzo. Su desarrollo fue motivado en parte por la incapacidad de los algoritmos de ML de resolver problemas de interés como son: el reconocimiento de objetos, y el reconocimiento de voz o el habla humana. También, el creciente desarrollo del poder de cómputo, especialmente con las unidades de procesamiento gráfico (GPU por sus siglas en inglés) hizo posible el uso práctico de estas técnicas. Principalmente, sus algoritmos están basados en diferentes tipos de redes neuronales: redes convolucionales, redes recurrentes, autocodificadores y autodecodificadores, redes con alimentación hacia adelante, entre otros [58]. Una de las características más importantes de deep learning, que lo diferencia de otras técnicas de ML, es que el proceso de extracción de *features* no se realiza manualmente, sino que el propio algoritmo es capaz de encontrar las *features* necesarias para el aprendizaje. Esta etapa de extracción de *features* está representada por las primeras capas ocultas de las redes, las cuales son capaces de separar los datos de entrada en diferentes niveles de abstracción y en diferentes *features*. Por ejemplo, en el caso del problema de la clasificación de las

flores que se introdujo al inicio, si se usa deep learning, los datos de entrada al modelo serían las imágenes de las flores y no las *features* extraídas manualmente de las mismas.

2.7.1. Redes neuronales profundas con alimentación hacia adelante

Las redes neuronales profundas hacia adelante (en inglés *deep feedforward networks*), o perceptrones multicapa (en inglés, *multilayer perceptrons*, MLPs) son un caso representativo de los modelos de deep learning. El objetivo de estas redes es aproximar una cierta función teórica f_t , a partir de los datos de entrenamiento \mathbf{x} . Por ejemplo, para un clasificador, $y = f_t(\mathbf{x})$ mapea la entrada \mathbf{x} a una categoría y . Las redes *feedforward* definen una relación $y = f(\mathbf{x}; \mathbf{W})$, y aprenden el valor de \mathbf{W} que resulta en la mejor aproximación de la función. El nombre *feedforward* se debe a que la información viaja en un único sentido, desde la entrada hacia la salida de la red, de modo tal que no existen conexiones de retroalimentación (en inglés, *feedback*).

Las redes *feedforward* son representadas por la composición de diferentes funciones. Por ejemplo, para el caso de tres funciones $f^{(1)}$, $f^{(2)}$ y $f^{(3)}$ conectadas en cadenas, se forma $f(\mathbf{x}) = f^{(3)}(f^{(2)}(f^{(1)}(\mathbf{x})))$. Esta estructura de cadenas es la más común dentro de las estructuras de redes neuronales [58]. Para este caso, $f^{(1)}$ se denomina primera capa, $f^{(2)}$ segunda capa y así sucesivamente. La longitud total de la cadena representa la profundidad de la red. El nombre “deep learning” proviene de esta terminología. La última capa se denomina capa de salida. Durante el entrenamiento, el objetivo es encontrar la función $f(\mathbf{x})$ que aproxime a $f_t(\mathbf{x})$. Los datos de entrenamiento especifican directamente qué tiene que hacer la capa de salida para producir la salida deseada. De esta manera, el comportamiento de las restantes capas no está directamente especificado por los datos de entrenamiento. El algoritmo de entrenamiento debe decidir cómo son usadas esas capas con el objetivo de producir la salida deseada. Como consecuencia, a estas capas se las denominan ocultas (en inglés, *hidden*). Cada capa representa a un vector, cuyos elementos se denominan neuronas. Si todas las neuronas de la capa j están conectadas con todas las neuronas de la capa $j+1$, para $j = 0, 1, \dots, J-1$, donde J es el número de capas de la red; entonces, a la red neuronal *feedforward* se le denomina densa o totalmente conectada (en inglés, *fully connected*). En la Figura 2.15 se muestra un ejemplo de red neuronal *feedforward* densa. En la misma, se identifican las capas de entrada, de salida, y las ocultas. Cada conexión entre las neuronas de diferentes capas se denominan pesos (o parámetros) (en inglés, *weight*), y son los valores que se “aprenden” durante el entrenamiento.

Las neuronas tienen una función de activación, g , la cual relaciona el valor de la señal a la entrada de las neuronas de la capa j , $\mathbf{q}^{(j)} = \mathbf{w}^{(j-1)}\mathbf{h}^{(j-1)} + \mathbf{b}^{(j)}$, con su salida $\mathbf{h}^{(j)}$,

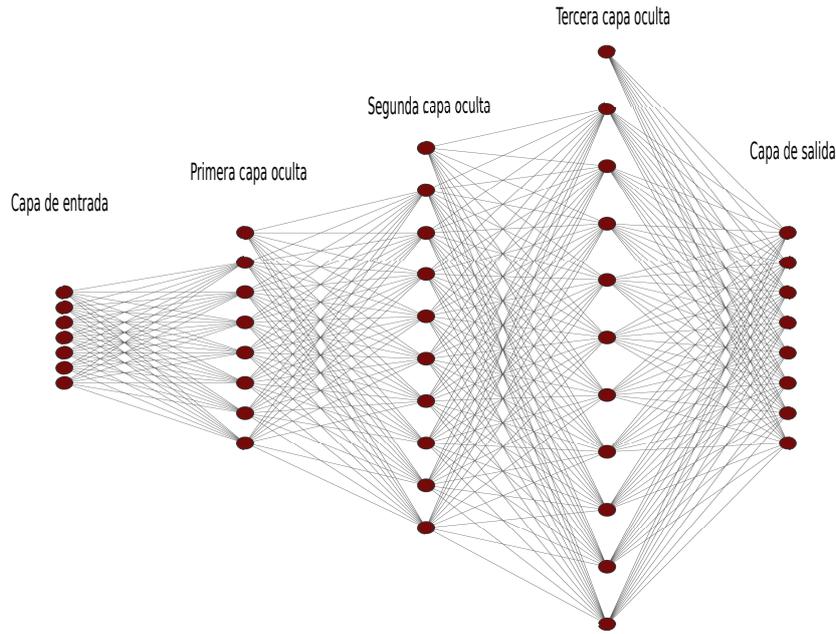


Figura 2.15: Ejemplo de red neuronal *feedforward* densa.

$$\mathbf{h}^{(j)} = g(\mathbf{q}^{(j)}) = g(\mathbf{w}^{(j-1)}\mathbf{h}^{(j-1)} + \mathbf{b}^{(j)}), \quad (2.37)$$

donde $\mathbf{w}^{(j-1)}$ es la matriz de pesos que relaciona la capa $j - 1$ con la capa j , y $\mathbf{b}^{(j)}$ es el vector de sesgo de la capa j . Existen diferentes funciones de activación, entre ellas encontramos: la función sigmoide [59], la tangente hiperbólica [60], la Relu [61], softmax [62], entre otras. Con esta representación, la capa 0 se corresponde con el vector de entrada \mathbf{x} , siendo $\mathbf{h}^{(0)} = \mathbf{x}$. En el caso de la clasificación, la capa de salida representa un vector de K elementos o clases; donde cada clase está representada por una neurona.

2.7.2. Entrenamiento de la red neuronal

Función de costo

Para entrenar una red neuronal, se define una función de costo o de pérdida (en inglés, *loss function*), la cual se utiliza para determinar si la red tiene buen rendimiento a la hora de realizar predicciones. De forma general, dado un conjunto de entrenamiento (\mathbf{x}_n, y_n) , con $n = 1, \dots, N$, la función de pérdida se escribe,

$$\text{Loss}(\mathbf{W}, \mathbf{x}_n, y_n) = \frac{1}{N} \sum_n^N L(f(\mathbf{x}_n, \mathbf{W}), y_n), \quad (2.38)$$

donde la función L depende tanto de los datos de entrenamiento, como del total de parámetros entrenables \mathbf{W} de la red. La elección de la misma depende del tipo de problema a resolver. Para los problemas de clasificación es habitual usar la función de

entropía cruzada (en inglés, *cross-entropy*). La función *cross-entropy* es una medida de cercanía entre dos distribuciones de probabilidades y se define de la siguiente forma,

$$L_{ce}(f(\mathbf{x}_n, \mathbf{W}), y_n) = - \sum_{i=1}^I p_{y,n}^i \ln(\hat{p}_{y,n}^i), \quad (2.39)$$

donde I es el número de clases, y $p_{y,n}^i$ es el elemento i -ésimo del vector que representa la probabilidad teórica de la capa de salida. Este vector de probabilidad es cero en todas sus componentes excepto en el índice determinado por la etiqueta de la clase, en el cual toma valor 1. Por su parte, $\hat{p}_{y,n}^i$ es el elemento i -ésimo del vector de probabilidades estimado por la red en la capa de salida. El objetivo del entrenamiento es lograr que $\hat{\mathbf{p}}_{y,n}$ sea lo más parecida a $\mathbf{p}_{y,n}$.

Dado que la capa de salida de la red tiene que representar un vector de probabilidades, es habitual usar la función de activación softmax. Si \mathbf{q} es el vector de valores de la capa de salida antes de aplicar la función de activación, entonces, la función softmax se define como,

$$\sigma(\mathbf{q})_i = \hat{p}_y^i = \frac{e^{q_i}}{\sum_{j=1}^I e^{q_j}}, \quad i = 1, \dots, I. \quad (2.40)$$

De la ecuación (2.40) se observa que el uso de la función softmax devuelve un vector de probabilidades, en el cual la suma de sus elementos es igual a la unidad.

Una vez definida la función de costo a minimizar, se necesita un algoritmo de optimización para encontrar los pesos \mathbf{W} . Existen varios métodos para lograr este propósito, los más usados en redes neuronales se basan en el descenso del gradiente [58].

Optimización

El problema del aprendizaje de una red neuronal se formula como una búsqueda de los parámetros \mathbf{W} , para los cuales la función de costo toma un valor mínimo. Si la función de costo se encuentra en un mínimo, entonces necesariamente su gradiente respecto a \mathbf{W} es igual a cero. En general, la función de costo es no lineal respecto a estos parámetros, por lo cual no es fácil encontrar fórmulas cerradas para calcularlos de forma eficiente. Por este motivo es que se adopta un método de búsqueda paso a paso de los parámetros \mathbf{W} , de forma de ir disminuyendo la función de costo. El descenso del gradiente es el predecesor de los métodos más usados en el entrenamiento de redes neuronales, como es el caso de los optimizadores RMSProp [63] y Adam [64]. El mismo, requiere información solamente del gradiente de la función de costo, por lo cual se enmarca dentro de los métodos de optimización de primer orden.

Sea $\mathbf{G}^{(k)} = \nabla_{\mathbf{W}} \text{Loss}(\mathbf{W}^{(k)}, \mathbf{x}_n, y_n)$ el gradiente de la función de costo respecto de

los pesos \mathbf{W} para el paso k -ésimo. Este gradiente se calcula usando el algoritmo de propagación hacia atrás (en inglés, *backpropagation*) [65], el cual utiliza la regla de la cadena del cálculo matemático [66] para encontrar las derivadas parciales de la función de costo respecto de todos los pesos de la red. El nombre *backpropagation* se debe a que se comienza desde la función de costo y se propaga el cálculo de derivadas parciales hacia el inicio de la red.

En cada paso del algoritmo del descenso del gradiente, la actualización de los pesos es de la forma,

$$\mathbf{W}^{(k+1)} = \mathbf{W}^{(k)} - \mathbf{G}^{(k)}\eta^{(k)}, \quad k = 0, 1, \dots, \quad (2.41)$$

donde el parámetro $\eta^{(k)}$ es la tasa de aprendizaje (en inglés, *learning rate*), la cual, en el caso general se puede ver como un vector de valores positivos. Sus componentes pueden ser fijas o variables a medida que transcurre el entrenamiento [58]. La dirección de máximo crecimiento de la función de costo está definida por su gradiente, por esta razón, la actualización de los pesos se toma en el sentido opuesto. El algoritmo de optimización finaliza cuando se llega a un criterio de optimalidad definido por el usuario.

Los pasos del algoritmo de descenso del gradiente con una tasa de aprendizaje fija, se pueden describir de la siguiente forma:

1. Inicializar los pesos \mathbf{W} de forma aleatoria con valores pequeños y elegir η .
2. Calcular la función de costo y verificar si se cumple el criterio para detener el algoritmo. En caso de que se cumpla, se finaliza el mismo, y los pesos en esta etapa son los obtenidos con el entrenamiento. En caso contrario, se continúa al siguiente paso.
3. Calcular el gradiente de la función de costo usando el algoritmo de back-propagation.
4. Actualizar los pesos usando la ecuación (2.41).
5. Ir al paso número 2.

Existen otros algoritmos de optimización, los cuales hacen uso de la matriz hessiana de la función de costo, y por este motivo son de segundo orden. Un ejemplo es el método de Newton [58]. Si bien los algoritmos de segundo orden convergen más rápido que los algoritmos de primer orden, estos usan mucha memoria para almacenar todas las derivadas parciales dobles de la matriz hessiana. Por esta razón, en el entrenamiento de redes de muchos parámetros, es común usar algoritmos de primer orden.

Los conjuntos de datos de entrenamiento en aplicaciones de deep learning suelen contener miles o millones de muestras. Debido a esto, en la práctica, usar todos los datos de entrenamiento al mismo tiempo para realizar la actualización de los pesos es

muy costoso. A los algoritmos que utilizan todo el conjunto de entrenamiento se los denominan determinísticos. Como alternativa, existen algoritmos que eligen de forma aleatoria un conjunto de m muestras de entrenamiento para cada actualización de los pesos. Si $m = 1$, al algoritmo se lo denomina estocástico. En cambio, si $m > 1$, al algoritmo se lo denomina estocástico por minilotes (en inglés, *minibatch stochastic*). De esta terminología provienen los nombres descenso estocástico del gradiente (SGD) y minibatch SGD. Las versiones estocásticas de los algoritmos de optimización, son las que se implementan en la práctica [58]. En este contexto, al parámetro m se lo denomina tamaño del batch (en inglés, *batch size*). La época (en inglés, *epoch*) es un concepto que se usa en el entrenamiento, es el intervalo que comprende desde una actualización de los pesos usando un batch determinado, hasta la siguiente actualización de los pesos sobre el mismo batch. Una época puede contener una o varias actualizaciones de los pesos, dependiendo del tamaño del *batch*. Por ejemplo, si el *batch size* es m y si los datos de entrenamiento tienen una longitud N múltiplo de m , entonces una época contendrá $\frac{N}{m}$ actualizaciones de los pesos.

Regularización

En general, si el número de parámetros entrenables en un modelo de ML aumenta, manteniendo fija la cantidad de datos de entrenamiento; la función de costo de entrenamiento disminuye, pero la de generalización aumenta. Este comportamiento se denomina *sobreaajuste*. Para los algoritmos de DL, los cuales presentan miles o millones de parámetros entrenables, el sobreaajuste es algo importante a tener en cuenta. La forma de evitar el mismo es a través de la regularización.

El término *regularización* se refiere a cualquier modificación que se haga sobre el algoritmo de aprendizaje, con el objetivo de disminuir el error de generalización, pero no el de entrenamiento. Existen diferentes formas de regularizar, y ninguna es mejor que otra; todo depende del problema particular a resolver [58]. Una de las formas más conocidas son las penalizaciones L1 y L2. Las mismas, introducen un término aditivo a la función de costo que depende de los pesos \mathbf{W} ,

$$\text{Loss}(\mathbf{W}) = \frac{1}{N} \sum_n^N L(f(\mathbf{x}_n, \mathbf{W}), y_n) + \nu \Omega(\mathbf{W}), \quad (2.42)$$

donde $\nu \in [0, 1]$ es el parámetro de regularización. Para L1, la función $\Omega(\mathbf{W}) = \sum_l |W_l|$, donde el índice l puede recorrer todos los parámetros entrenables del modelo. Para L2, $\Omega(\mathbf{W}) = \sum_l W_l^2$. Ambas penalizaciones buscan reducir la magnitud de los parámetros \mathbf{W} , con el objetivo de evitar el sobreaajuste. La intensidad de la regularización depende del valor de ν .

Existen otras formas de regularización, entre ellas se encuentran: la eliminaciones de

conexiones de la red (en inglés, *dropout*) a la hora de realizar actualizaciones de los pesos [67], normalización de lote (en inglés, *batch normalization*) [68], detención temprana (en inglés, *early stopping*) [69], combinaciones de L1 y L2, entre otras [58]. En particular, en esta tesis se usa el método *early stopping*, el cual consiste en monitorear alguna métrica (por ejemplo la función de loss de validación o el accuracy de validación, entre otras), y de esta forma definir un criterio para detener el entrenamiento si se observa que empeora la generalización en función de las épocas.

2.7.3. Redes convolucionales

Las redes convolucionales (CNN por sus siglas en inglés) son un tipo especial de redes neuronales. Tienen como particularidad que, al menos una de sus capas presenta la operación de convolución. Las mismas han sido muy utilizadas en el campo de visión artificial y clasificación de imágenes [70]. Las capas convolucionales están constituidas por núcleos (en inglés, *kernels*) de un tamaño determinado. Cada uno de los núcleos se convoluciona con la capa anterior y de esta forma el resultado se almacena en una estructura de salida, de dimensiones dependientes del kernel y de la capa anterior. En la Figura 2.16 se muestra la operación de convolución para una capa de entrada y un kernel de dos dimensiones. En las capas convolucionales, los parámetros a entrenar son los coeficientes de los filtros. En general, la dimensión de la convolución está determinada por las dimensiones de la capa anterior y del kernel. Para la presente tesis se utilizan capas convolucionales en una dimensión, dada las características de la señal de entrada a las redes, las cuales son representadas por vectores unidimensionales.

Al igual que para las neuronas de las redes densas, al resultado de la convolución se le aplica una función de activación. A las redes convolucionales se las puede separar en dos etapas: la primera es la extracción de características usando capas convolucionales, y la segunda es la etapa de clasificación o regresión; en la que se usan capas densas.

2.8. Conclusiones

En este capítulo se realizó una descripción de los diferentes componentes del radar meteorológico. Se estudió su principio de funcionamiento y el modelo de señal recibida. Se introdujeron conceptos importantes como la *ecuación radar meteorológico*, volumen de resolución, las ambigüedades, tanto en rango como en velocidad, la conformación y el muestreo de la señal a la salida del receptor. Se presentó el modo *staggered* como posible solución a la relación de compromiso que existe entre la velocidad máxima no ambigua y el rango máximo no ambiguo. Se definieron los momentos espectrales y se observó su relación con la DEP. Por otro lado, se presentaron algunas de las herramientas de procesamiento Doppler más usadas en la literatura y se diferenciaron entre las que se

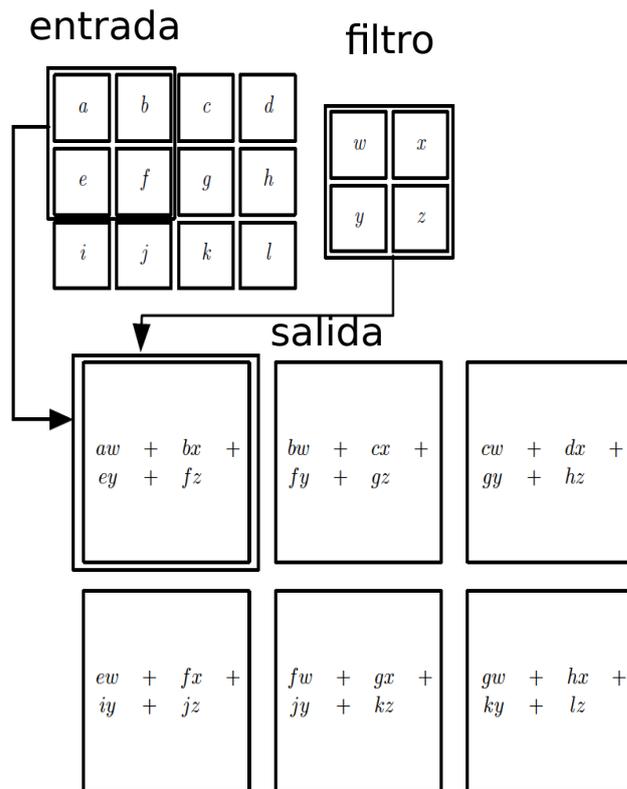


Figura 2.16: Operación de convolución en dos dimensiones.

aplican para el modo convencional de operación del radar y para el modo *staggered*, en particular *staggered 2/3*. Para el modo convencional se presentó el algoritmo PPP para la estimación de los momentos espectrales sin la presencia de clutter terrestre. Se introdujo el problema de mitigación de clutter y se describieron los algoritmos GMAP y GMAP-TD como posible solución al filtrado de clutter y estimación de los momentos espectrales. Por otro lado, cuando se usa el modo *staggered* se extendieron las ideas de PPP y se describió el algoritmo de estimación de velocidad DA. También, se realizaron observaciones sobre el algoritmo GMAP-TD para su aplicación a secuencias *staggered*. Además, se realizó una breve descripción de los datos a usar en esta tesis para validar los algoritmos propuestos. Por último, se realizó una breve introducción al ML y al DL, en la cual se explicó sucintamente el procedimiento para entrenar redes neuronales. Se hizo énfasis en los aspectos más importantes del mismo, tales como la elección de la función de costo, la optimización y la regularización. También se introdujeron los conceptos de redes *feedforward* y redes convolucionales.

Capítulo 3

Corrección del ancho espectral del clutter y GMAP-NU

“La ciencia no conoce la deuda que tiene con la imaginación.”

— Ralph Waldo Emerson

3.1. Introducción

En algoritmos que se implementan en el dominio de las frecuencias como es el caso de GMAP, introducido en el Capítulo 2, es necesario tener conocimiento de las propiedades del clutter y control sobre el efecto que el procesamiento pueda tener sobre este y su espectro, al momento de filtrarlo. Si el clutter no es suprimido correctamente produce una degradación en las estimaciones de potencia, velocidad Doppler media y ancho espectral del fenómeno. Por esta razón, se propone una corrección al ancho espectral del clutter, presentado en [39] bajo el marco de la presente tesis, en el cual se tiene en cuenta el efecto de la ventana usada durante el procesamiento de la señal meteorológica.

Por otro lado, como se mencionó en la Sección 2.2.3, para el modo convencional de operación del radar, existe una relación de compromiso entre la velocidad máxima no ambigua y el rango máximo no ambiguo, incrementar uno de los anteriores implica disminuir el otro. Este problema se resuelve adoptando el modo de operación *staggered* introducido en la Sección 2.2.3. En caso de usar dos PRIs (T_1 y T_2), la velocidad máxima no ambigua depende inversamente de la diferencia $T_2 - T_1$, mientras que el rango máximo no ambiguo depende de forma proporcional con la menor de las PRIs. Si bien este modo resuelve la relación de compromiso mencionada anteriormente, el mismo hace que la señal adquirida, en tiempo lento, presente un muestreo no uniforme, para lo

cual no se pueden aplicar las técnicas clásicas de procesamiento como una Transformada de Fourier, sino que hay que emplear o desarrollar nuevas herramientas.

Por el motivo anterior, en este capítulo también se introduce el método GMAP no Uniforme (GMAP-NU), presentado en [40] dentro del marco de la presente tesis, que combina dos algoritmos existentes de diferentes áreas, con el objetivo de procesar la señal radar muestreada de forma no uniforme. Por un lado, GMAP-NU utiliza un algoritmo de reconstrucción espectral para obtener, a partir de una secuencia no uniforme, una secuencia uniforme. Posteriormente se aplica GMAP y se estiman los momentos espectrales. Si bien el algoritmo de reconstrucción espectral puede ser aplicado a cualquier relación y números de PRIs, en este capítulo se aplica a señales obtenidas con el modo de operación *staggered 2/3*.

El capítulo está organizado de la siguiente manera. En la Sección 3.2 se aborda el problema de la corrección del ancho del clutter con el objetivo de mejorar el proceso del filtrado de clutter. En la Sección 3.3 se presenta el algoritmo GMAP-NU y mediante simulaciones numéricas se analiza su desempeño. Por último, en la Sección 3.4 se presentan conclusiones.

3.2. Corrección del ancho espectral del clutter

3.2.1. Formulación del problema

Como se mencionó en la Sección 2.4.3, en GMAP se construye una máscara gaussiana para filtrar el clutter terrestre, siendo el ancho espectral del mismo, σ_c , un parámetro conocido. Usar un valor para el ancho del clutter mayor o menor que σ_c lleva a filtrar de más o filtrar de menos las componentes espectrales, lo que en ambos casos repercute sobre la calidad de los estimados de los momentos espectrales del fenómeno meteorológico. Por este motivo, se propone una forma de estimar σ_c usando el conocimiento sobre las características físicas de la antena del radar y de la ventana usada en el procesamiento.

En la práctica, el número de muestras en la dirección tiempo lento equivalente a un CPI está acotado por la velocidad de rotación de la antena, su ancho de haz de mitad de potencia en la dirección acimutal y por la PRI. Esto implica, naturalmente, que la secuencia adquirida por el radar en esa dirección es de duración finita, pero además suele incluir solo unas pocas muestras, lo cual se modela empleando una ventana rectangular. Si el clutter es muy intenso existe la posibilidad de que los lóbulos secundarios del mismo, debido a la secuencia finita, enmascaren parcial o completamente el espectro del fenómeno. El uso de ventanas distintas a la rectangular reduce los lóbulos secundarios del clutter en el espectro, a expensas del aumento del ancho del lóbulo principal [52]. Por lo cual, es importante tener presente el efecto de la ventana para el correcto diseño

de la máscara de clutter.

Existen dos conceptos importantes relacionados al clutter terrestre. El primero se refiere al clutter *asintótico* o *teórico*, el cual es el obtenido si se contara con una secuencia de infinitas muestras y posee un ancho σ_t . Es consecuencia del movimiento de la antena, lo cual produce decorrelación entre los pulsos en tiempo lento [3]. Si la antena apuntara siempre en la misma dirección, y el clutter fuese estático, entonces, se observaría en el espectro una función delta en la velocidad cero. La DEP asintótica del clutter se modela con forma gaussiana de potencia P_t , varianza σ_t^2 , y centrada en velocidad cero,

$$S_t(v) = \frac{P_t}{\sqrt{2\pi}\sigma_t} e^{-\frac{v^2}{2\sigma_t^2}}. \quad (3.1)$$

Para bajos ángulos de elevación σ_t se calcula como [3],

$$\sigma_t = \frac{w_r \lambda \sqrt{\ln 2}}{2\pi \theta_{3dB}}, \quad (3.2)$$

donde w_r es la velocidad de rotación de la antena y θ_{3dB} es el ancho de haz de mitad de potencia de la antena en acimut.

El segundo concepto se refiere a la DEP del clutter *observado*, la cual tiene en cuenta el efecto de la ventana, y su ancho se denota σ_c . Teóricamente, esta DEP se obtiene de la convolución entre la DEP asintótica del clutter y la densidad espectral de energía (DEE) de la ventana [46].

Para ilustrar los conceptos antes mencionados, a modo de ejemplo se simula una secuencia de datos IQ generada con un único PRI y se estudia la etapa de filtrado de clutter empleando el algoritmo GMAP. En la Figura 3.1(a) se muestra la máscara de clutter construida utilizando ventana de Hamming, y sin tener en cuenta su efecto, es decir empleando directamente el valor de σ_t en la etapa de construcción de la máscara. En la Figura 3.1(b) se observa la DEP filtrada luego de aplicar la máscara descrita. Se observa que el clutter no fue eliminado completamente, lo cual conlleva a la estimación sesgada de los momentos espectrales. Por otro lado, el uso de un ancho del clutter para construir la máscara mayor a σ_c también produce sesgo en la estimación de los momentos, debido a que en general se elimina una fracción importante del espectro del fenómeno, lo que se vuelve crítico a medida que la velocidad Doppler media del fenómeno se encuentra próxima a cero.

3.2.2. Descripción de la corrección

Cuando se trabaja con señales determinísticas, donde el espectro es directamente la Transformada de Fourier (TF) de la señal, es simple visualizar que el espectro de una secuencia afectada por una ventana es la convolución de la TF de la secuencia con

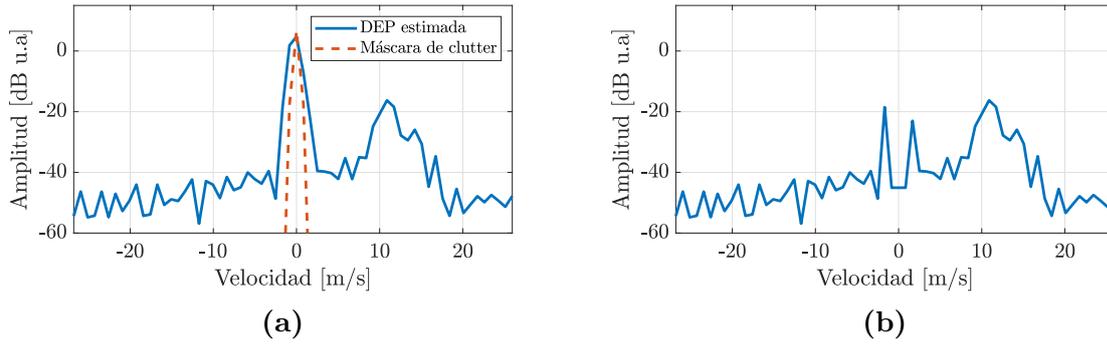


Figura 3.1: Ejemplo de máscara de clutter y DEP filtrada sin corregir el ancho del clutter. (a) DEP y máscara. (b) DEP filtrada.

la TF de la ventana en cuestión. Cuando se trabaja con procesos aleatorios, como en este caso, ocurre un efecto análogo pero a nivel de densidades espectrales de potencia o de energía.

Considerando que $V[n]$ es la señal recibida en tiempo lento para una dada celda de rango, modelada con un proceso aleatorio estacionario, y que $w[n]$ es la ventana que la trunca a M muestras, entonces $Y[n] = V[n]w[n]$ es la señal que se observa. Luego, la autocorrelación estadística de $Y[n]$ está dada por [46]

$$R_Y[m] = \langle \mathbb{E}\{Y(n+m)Y^*[n]\} \rangle = \langle \mathbb{E}\{V(n+m)w[n+m]V^*[n]w[n]\} \rangle, \quad (3.3)$$

donde $\langle \cdot \rangle$ es el operador promedio temporal. Debido a que $V[n]$ se supone estacionario y que $w[n]$ es una señal determinística, entonces se $R_Y[m]$ se puede factorizar como

$$R_Y[m] = \mathbb{E}\{V(n+m)V^*[n]\} \langle w[n+m]w[n] \rangle. \quad (3.4)$$

Teniendo en cuenta que tanto $w[n]$ como $Y[n]$ son señales de energía, pero se pretende evaluar una DEP que aproxime a la DEP de la señal de potencia $V[n]$, entonces el promedio temporal está definido por

$$\langle w[n+m]w[n] \rangle = \frac{1}{M} \sum_{n=-\infty}^{\infty} w[n+m]w[n] = \frac{1}{M} r_w[m], \quad (3.5)$$

siendo $r_w[m]$ la autocorrelación de una señal determinística de energía [71]. Por lo tanto

$$R_Y[m] = \frac{1}{M} R_V[m] r_w[m]. \quad (3.6)$$

A partir de la relación de Wiener-Khinchin [36], aplicando la TDF a la ecuación (3.6) se obtiene la DEP de la M -periodización de $Y[n]$, la que resulta

$$S_Y[k] = \frac{1}{M} \{S_V \otimes S_w\}[k], \quad (3.7)$$

donde \otimes denota el producto de convolución circular, $S_V[k]$ es la DEP de $V[n]$ y $S_w[k]$ es la densidad espectral de energía (DEE) de $w[n]$, la cual está dada por [71]

$$S_w[k] = |W[k]|^2, \quad (3.8)$$

siendo $W[k]$ la TDF de $w[n]$. La ecuación (3.7) muestra que la DEP de $Y[n]$ es la convolución de la DEP de $V[n]$ con la DEE de $w[n]$ y sobre este resultado se sustenta el método de corrección propuesto.

Ajuste de la función gaussiana

La DEE de la ventana $w[n]$ se puede expresar en términos de velocidad como

$$S_w[v_k] = |W[v_k]|^2, \quad (3.9)$$

donde $W[v_k]$ es simplemente $W[k]$, luego de hacer el cambio de variables de frecuencia a velocidad, siendo v_k y $k = 1, \dots, M$; las velocidades discretas en las que se evalúa la DEE.

El método consiste en ajustar a la DEE una función gaussiana de la forma

$$Q_w[v_k] = P_w e^{-\frac{v_k^2}{2\sigma_w^2}}, \quad (3.10)$$

donde P_w y σ_w^2 son la energía y la varianza de la gaussiana, respectivamente. Los valores de estos parámetros son los que se desean estimar a partir del ajuste. Es común para este tipo de problemas usar el criterio de mínimo error cuadrático medio entre $S_w[v_k]$ y $Q_w[v_k]$.

Por otro lado, se puede demostrar que la convolución de dos funciones gaussianas centradas en cero, con varianzas σ_1^2 y σ_2^2 , resulta en una función gaussiana centrada en cero y varianza $\sigma_3^2 = \sigma_1^2 + \sigma_2^2$.

Con las definiciones anteriores, la DEP del clutter *observado* resulta

$$S[v_k] = \frac{P_c}{\sqrt{2\pi\sigma_c}} e^{-\frac{v_k^2}{2\sigma_c^2}}, \quad (3.11)$$

donde $P_c = P_t P_w$ y el ancho espectral resulta

$$\sigma_c = \sqrt{\sigma_t^2 + \sigma_w^2} \quad (3.12)$$

Entonces, la corrección consiste en usar la ecuación (3.12) para evaluar el ancho del espectro del clutter, en la construcción de la máscara. Es importante notar que a medida que M aumenta, el ancho de la DEE de la ventana disminuye; siendo en el

Ventana	Parámetros	Número de muestras, M		
		32	64	128
Hamming	\hat{P}_w	12,2931	24,9538	50,27
	$\hat{\sigma}_w$	$0,0173v_a$	$0,0086v_a$	$0,0043v_a$
Blackman	\hat{P}_w	9,50	19,3198	38,9404
	$\hat{\sigma}_w$	$0,0224v_a$	$0,0110v_a$	$0,0055v_a$

Tabla 3.1: Ajuste gaussiano de las ventanas Hamming y Blackman.

límite para $M \rightarrow \infty$ igual a cero. De la ecuación (3.12) se observa que mientras σ_w disminuye, σ_c se aproxima a σ_t .

En las situaciones prácticas de los radares meteorológicos, el número de muestras en un CPI es pequeño, por lo cual la ventana utilizada en el procesamiento produce un ensanchamiento apreciable en la DEP.

3.2.3. Resultados

Con el objetivo de ajustar la función gaussiana a la DEE de la ventana, se usa el algoritmo Gauss-Newton [72] para resolver numéricamente el problema de mínimos cuadrados no lineal. En la Tabla 3.1 se presentan los valores estimados de P_w y σ_w obtenidos a partir del ajuste gaussiano usando diferentes valores de M , para las ventanas Hamming y Blackman. Los valores estimados de σ_w se reportan en función de la velocidad máxima no ambigua v_a .

Retomando el ejemplo de la Sección 3.2.1, en la Figura 3.2 se presenta el proceso de filtrado empleando el algoritmo GMAP, cuando se emplea el ancho del clutter corregido para la construcción de la máscara. De la Figura 3.2(a) se observa que en esta ocasión la máscara cubre completamente el lóbulo del clutter terrestre. Por este motivo, en contraposición con lo que ocurre en la Figura 3.1(b), en la Figura 3.2(b) se aprecia que todo el clutter fue filtrado correctamente y no hay componentes del mismo presentes, lo que evita el sesgo en las estimaciones, lo cual mejora la reconstrucción del espectro del fenómeno y el desempeño de la estimación de los momentos espectrales.

En pos de cuantificar el efecto de la corrección del ancho espectral del clutter sobre los estimadores de los momentos espectrales del fenómeno, se realizan simulaciones numéricas de tipo Monte Carlo. El experimento consiste en variar la velocidad del fenómeno, generando 1000 realizaciones de datos sintéticos para cada valor, manteniendo fijos los demás parámetros de la simulación: $M = 64$, PRF = 2000 Hz, CSR = 40 dB, SNR = 20 dB, $S_p = 1$ u.a (unidades arbitrarias), $\sigma_c = 0,25$ m/s, $\sigma_p = 2$ m/s. Se utilizan el sesgo y la desviación estándares como métrica. Dado un parámetro x , el sesgo se define como la diferencia entre un valor estimado, \hat{x} , y el valor verdadero, x_v ,

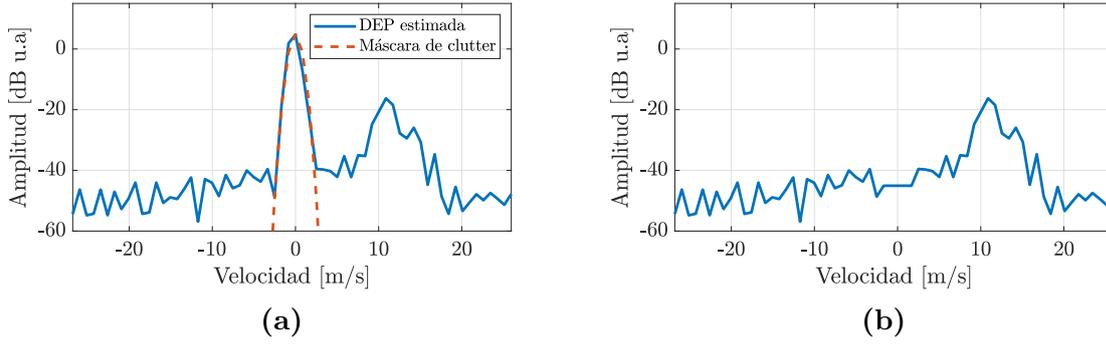


Figura 3.2: Ejemplo de máscara de clutter y DEP filtrada con corrección del ancho del clutter. (a) DEP y máscara. (b) DEP filtrada.

que toma dicho parámetro. En el contexto de las simulaciones de Monte Carlo, para L realizaciones, el sesgo y la desviación estándar (*std*) se calculan como

$$sesgo = \frac{1}{L} \sum_{l=1}^L \hat{x}_l - x_v, \quad (3.13)$$

$$std = \sqrt{\frac{1}{L-1} \sum_{l=1}^L |\hat{x}_l - x_v|^2}, \quad (3.14)$$

donde \hat{x}_l representa los estimados obtenidos para cada realización.

En la Figura 3.3 se observa el análisis de error para el algoritmo GMAP con y sin corrección del ancho espectral del clutter. De los resultados se aprecia que para la estimación de potencia y velocidad Doppler en la situación donde no se realiza la corrección los sesgos son grandes. Esto se debe al remanente del espectro del clutter, lo cual hace que la estimación de potencia quede dominada por esos pocos puntos de la DEP del clutter, mostrando gran variabilidad, y que siempre la velocidad estimada se encuentre cercana a cero, mostrando poca variabilidad. En el caso de la estimación del ancho espectral, el resultado sin la corrección parece ser mejor, pero no es así. Lo que ocurre en esa situación es que siempre se está estimando un valor $\hat{\sigma}_p$ entre el ancho espectral del clutter (debido al remanente que queda de clutter) y el ancho espectral real del fenómeno. Debido al sesgo que introduce el espectro remanente del clutter, se observa menos variabilidad en la estimación y por ende menor *std*. El desempeño de GMAP utilizando la corrección se analiza en detalle en la siguiente sección.

3.3. GMAP no uniforme (GMAP-NU)

En esta sección se presenta el método GMAP-NU, el cual aborda el problema de filtrado de clutter y estimación de momentos espectrales para secuencias *staggered*, en especial *staggered 2/3*. Como se mencionó en el Capítulo 2, GMAP se diseñó para

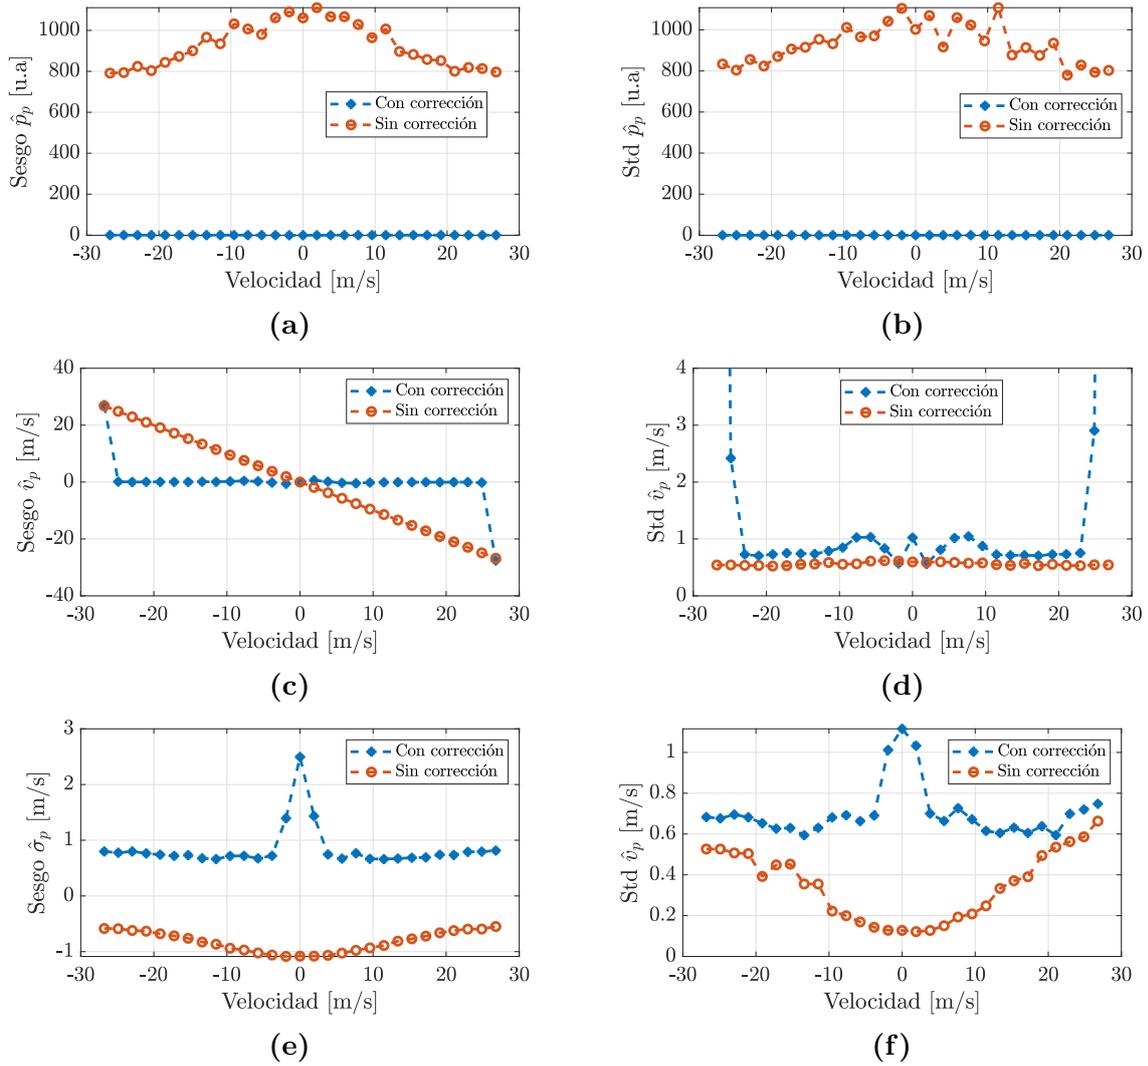


Figura 3.3: Análisis de errores en la estimación de los momentos espectrales para el algoritmo GMAP con y sin corrección del ancho espectral del clutter. (a) Sesgo de la potencia. (b) Desviación estándar de la potencia. (c) Sesgo de la velocidad. (d) Desviación estándar de la velocidad. (e) Sesgo del ancho espectral. (f) Desviación estándar del ancho espectral.

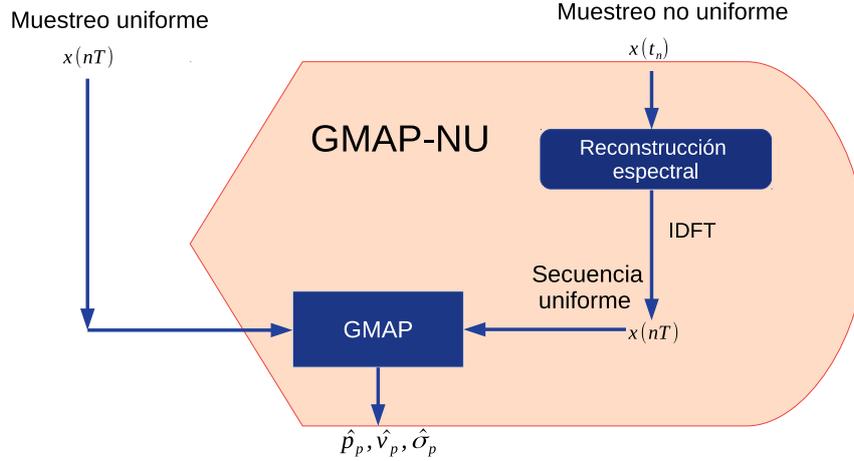


Figura 3.4: Diagrama en bloques del algoritmo GMAP-NU.

procesar secuencias uniformes. Por esa razón, en GMAP-NU se propone combinar un algoritmo de reconstrucción espectral que permite obtener una secuencia muestreada uniformemente a partir de una cuyo muestreo es no uniforme [73], para posteriormente emplear GMAP. En la Figura 3.4 se muestra el diagrama en bloques de GMAP-NU y se compara con el uso tradicional de GMAP.

3.3.1. Reconstrucción del espectro

Suponiendo que se tiene una secuencia $x(t_n)$ obtenida de muestrear una señal limitada en banda $x(t)$, donde los instantes t_n no están igualmente espaciados, pero presentan una estructura periódica, de período L , de forma tal que se puede escribir $t_n = nT + \Delta n$, siendo $n = kL + l$, k entero y varía entre $-\infty$ hasta ∞ y l desde 0 hasta $L - 1$. En resumen $t_n = kLT + lT + r_l T$, donde $r_l = \frac{\Delta n}{T}$ es una fracción del corrimiento de la muestra real obtenida si se hubiese muestreado de manera uniforme con período $T = \frac{T_1 + T_2 + \dots + T_L}{L}$. En [73] se demuestra que para las señales adquiridas bajo la suposición anterior, si son limitadas en banda en el intervalo $(\frac{-1}{2T}, \frac{1}{2T})$, entonces se puede reconstruir el espectro continuo $X_c(f)$ de la señal $x(t)$ a partir de las muestras $x(t_n)$.

Definiendo

$$X_{d2}(f) = \sum_{n=-\infty}^{n=\infty} x(t_n) e^{-j2\pi f t_n}, \quad (3.15)$$

es posible demostrar que [73]

$$X_{d2}(f) = \frac{1}{T} \sum_{k=-\infty}^{k=\infty} A(k) X_c\left(f - \frac{k}{LT}\right), \quad (3.16)$$

siendo

$$A(k) = \frac{1}{L} \sum_{l=0}^{l=L-1} e^{-jkr_l(2\pi/L)} e^{-jkl(2\pi/L)}. \quad (3.17)$$

En la práctica el número total de muestras M de la señal muestreada es finito. A partir de la ecuación (3.16) se obtiene un sistema de ecuaciones lineales de $L \times L$, en el cual $X_c(f)$ para cada f es la incógnita, la matriz de coeficientes la constituyen los valores de $A(k)$ y $X_{d2}(f)$ hace las veces de término independiente. Cabe destacar que $A(k)$ no depende de la frecuencia, por lo que la matriz de coeficientes se calcula una única vez, haciendo que este algoritmo sea eficiente desde el punto de vista computacional. Con el objetivo de reconstruir el espectro $X_c(f)$ en una grilla uniforme, los valores de f se eligen de forma igualmente espaciada como $f = \frac{i}{IT}$, donde i es entero y varía entre $\frac{-I}{2}$ y $\frac{I}{2} - 1$, e I es un número par. Finalmente, las muestras $x(nT)$ son obtenidas aplicando la IDFT a $X_c(\frac{i}{IT})$.

Un caso particular de la situación descrita anteriormente es el esquema de muestreo que resulta en el modo de operación *staggered* en radar, en el cual $L = 2$ cuando se emplean dos PRIs. Con esta idea surge GMAP-NU. Siguiendo la rama de la derecha de la Figura 3.4, la propuesta consiste en emplear el algoritmo descrito para obtener la secuencia uniformemente muestreada $x(nT)$ a partir de la secuencia original $x(t_n)$. Luego, se utiliza el algoritmo GMAP convencional que se describió en la Sección 2.4.3.

La idea es interesante debido a que evita lidiar con técnicas de filtrado directamente sobre la secuencia muestreada de manera no uniforme, ya que permite utilizar estrategias de filtrado diseñadas para PRI uniforme. Sin embargo, GMAP-NU presenta la limitación en cuanto a la velocidad máxima no ambigua que puede resolver, la cual está restringida por el algoritmo de reconstrucción espectral. Para *staggered 2/3* se obtiene $v_{max} = \frac{2\lambda}{4(T_1+T_2)} = \frac{2v_a}{5}$. Es decir, con GMAP-NU solamente se puede resolver correctamente 2/5 de la velocidad máxima no ambigua que permite el modo *staggered 2/3*. Cabe mencionar que una de las ventajas de GMAP-NU es que puede ser aplicado a cualquier relación y número de PRIs dada la estructura periódica que presenta la señal en estas condiciones, lo cual permite que se pueda obtener una secuencia uniforme mediante el algoritmo de reconstrucción espectral previamente introducido. Por otro lado, la restricción en cuanto a la velocidad máxima no ambigua hace que el método propuesto sea poco atractivo para aplicaciones reales.

3.3.2. Resultados

Con el objetivo de analizar el desempeño de GMAP-NU, se realizan simulaciones numéricas de tipo Monte Carlo. Para ello se generan 1000 realizaciones de datos sintéticos *staggered 2/3* para cada valor de velocidad y ancho espectral del fenómeno y se utilizan el sesgo y la desviación estándar de los estimados como métrica. Los parámetros

Parámetro	Símbolo	Valor
Frecuencia de portadora	F_c [GHz]	5,6
Longitud de onda	λ [cm]	5,35
Relación señal-ruido	SNR [dB]	20
Relación clutter-señal	CSR [dB]	40
Potencia del fenómeno	p_p [u.a]	1
Ancho teórico del clutter	σ_t [m/s]	0,25
Nro. de muestras (pulsos)	M	64
PRI 1	T_1 [ms]	1
PRI 2	T_2 [ms]	1.5
Velocidad máxima no ambigua	v_a [m/s]	26,8
Velocidad máxima del método	v_{max} [m/s]	10,7

Tabla 3.2: Parámetros para la simulación.

de las simulaciones se detallan en la Tabla 3.2. La velocidad Doppler media empleada se toma en todo el intervalo Doppler, mientras que para σ_p se usan los valores 2 m/s y 4 m/s. Con fines comparativos, también se incluye el análisis de desempeño de GMAP con datos sintéticos generados que poseen los parámetros de la señal presentados en la Tabla 3.2, pero con PRI uniforme igual a $T_u = \frac{T_1+T_2}{2} = 1,25$ ms, lo que equivale a una velocidad máxima no ambigua de $v_{a1} = 10,7$ m/s

En la Figura 3.5 se observa el análisis de error en la estimación de los momentos espectrales para los algoritmos GMAP y GMAP-NU. De los resultados se destaca que tanto GMAP como GMAP-NU presentan comportamientos similares para el rango de velocidades estudiados, lo cual es un resultado satisfactorio y valida el funcionamiento del algoritmo de reconstrucción del espectro. De la Figura 3.5(a) se observa que para $\sigma_p = 2$ m/s existe sesgo en la potencia en ambos algoritmos, el cual disminuye a medida que v_p aumenta. Este sesgo es consecuencia de que se remueve gran parte del espectro del fenómeno en la etapa de filtrado del clutter a causa de la superposición que presentan para velocidades bajas y bajo ancho espectral. Para velocidades cercanas a v_{max} GMAP-NU presenta sesgo debido a que en esas condiciones el algoritmo de reconstrucción deja de funcionar correctamente, ya que parte del espectro se encuentra en velocidades mayores a la máxima permitida, violando la hipótesis de ancho de banda enunciada en la Sección 3.3.1. Este efecto es más notorio a mayor valor de σ_p .

Para la velocidad Doppler media, de la Figura 3.5(c) se observa que ambos algoritmos se pueden considerar insesgados desde el punto de vista práctico, excepto para $\sigma_p = 2$ m/s alrededor de $v_p = 3$ m/s, situación en la cual el sesgo aumenta producto de la asimetría del espectro del fenómeno después del filtrado del clutter. Para veloci-

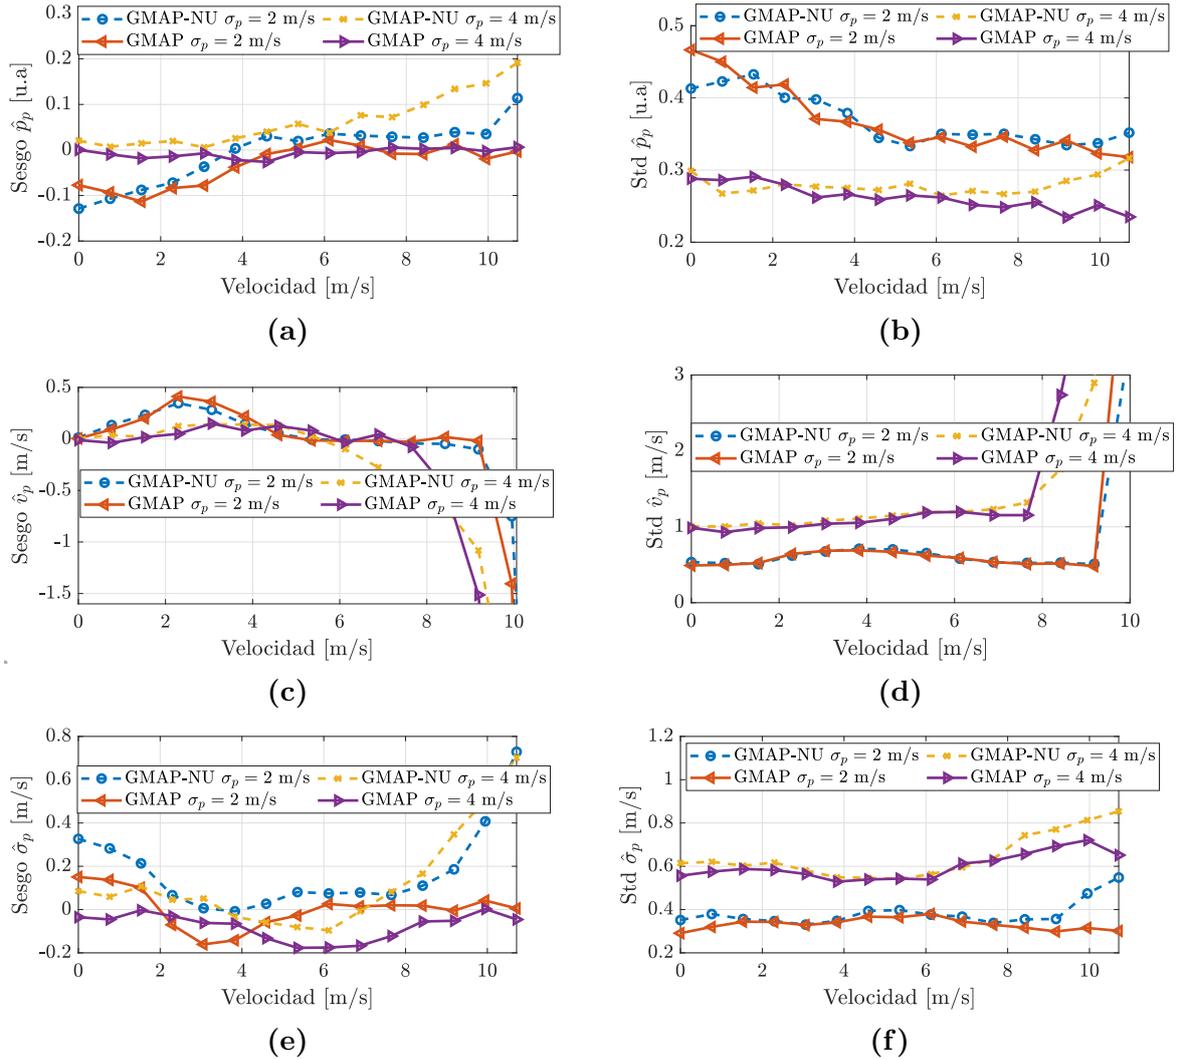


Figura 3.5: Análisis de errores en la estimación de los momentos espectrales para los algoritmos GMAP y GMAP-NU. (a) Sesgo de la potencia. (b) Desviación estándar de la potencia. (c) Sesgo de la velocidad. (d) Desviación estándar de la velocidad. (e) Sesgo del ancho espectral. (f) Desviación estándar del ancho espectral.

dades cercanas a v_{max} , GMAP-NU comienza a reportar estimaciones sesgadas debido a la mala reconstrucción del espectro, tal y como fue mencionado para la estimación de potencia. Por su parte GMAP también presenta sesgo en velocidades cercanas a v_{a1} debido al efecto de replicado.

Por su parte, en la estimación del ancho espectral, de la Figura 3.5(e) se aprecia que tanto GMAP como GMAP-NU reportan valores sesgados para velocidades alrededor del origen cuando $\sigma_p = 2$ m/s, siendo más notorio el sesgo para GMAP-NU. Para las desviaciones estándar de los tres estimados, de las Figuras 3.5(b), 3.5(d) y 3.5(f) se observa que ambos algoritmos tienen un desempeño similar, y que para velocidades cercanas a v_{max} GMAP-NU tiende a aumentar el valor de la desviación estándar (std) respecto a GMAP debido a la mala reconstrucción del espectro de la señal.

En general, de los resultados obtenidos se observa que GMAP-NU cumple satisfactoriamente el propósito para el que fue diseñado. Logrando estimar los momentos espectrales de las señales meteorológicas en modo *staggered 2/3* con un desempeño similar al de GMAP aplicado a señales adquiridas en el modo convencional bajo las mismas condiciones de simulación.

3.4. Conclusiones

En este capítulo se presentó, por un lado, una corrección en la estimación del ancho del clutter a partir de su ancho teórico. Por otro lado, se introdujo el algoritmo GMAP-NU como solución al problema de filtrado de clutter terrestre y estimación de momentos espectrales de señales adquiridas en modo *staggered 2/3*.

Con respecto a la corrección del ancho espectral del clutter se tuvo en cuenta la influencia de la ventana usada durante el procesamiento. Para ello se analizó por separado la contribución del clutter teórico y la de la ventana. Posteriormente se ajustó una función gaussiana al lóbulo principal de la DEE de esta última y se utilizó el resultado de la convolución de dos funciones gaussianas para obtener un estimador para el ancho espectral del clutter. Además, mediante un ejemplo simulado empleando datos sintéticos se mostraron las consecuencias en el filtrado de usar el ancho espectral de clutter teórico y el ancho espectral de clutter corregido para la construcción de la máscara. El ejemplo muestra que no corregir correctamente el ancho espectral del clutter conlleva a que luego del filtrado se conserven componentes residuales del espectro del clutter que repercuten sobre la estimación de los momentos espectrales del fenómeno. También se apreció que con la corrección introducida, la máscara es capaz de eliminar totalmente las componentes de clutter, llevando a una mejora en el desempeño de los algoritmos de estimación de los momentos.

Por su parte, el algoritmo GMAP-NU se diseñó a partir de la combinación de dos métodos existentes en diferentes áreas del procesamiento de señales. Por un lado,

se usó un método de reconstrucción espectral, el cual permite a partir de una señal limitada en banda y muestreada de forma no uniforme (pero que presenta un patrón periódico) reconstruir su espectro en una grilla uniforme, para de esta forma mediante la antitransformada de Fourier obtener una secuencia muestreada de forma uniforme. Por otro lado, a partir de esta nueva secuencia, con el objetivo de filtrar el clutter y estimar los momentos espectrales del fenómeno se utiliza GMAP tal y como fue presentado en la Sección 2.4.3. Mediante simulaciones numéricas de tipo Monte Carlo, se estudió el desempeño de GMAP-NU tomando como métricas el sesgo y la desviación estándar de los estimados. Además, se comparó el desempeño de GMAP-NU con el de GMAP para los mismos parámetros de simulación, excepto que para GMAP se generaron datos sintéticos en una grilla uniforme. Los resultados obtenidos fueron satisfactorios y comparables con los de GMAP. Si bien es una idea atractiva, es importante mencionar que GMAP-NU presenta una restricción muy fuerte en cuanto a la velocidad máxima no ambigua que puede resolver (impuesta por el algoritmo de reconstrucción espectral), impidiendo explotar completamente el propósito del modo *staggered 2/3*. Sin perjuicio de lo cual, GMAP-NU constituye el punto de partida para entender el problema de filtrado de clutter y estimación de momentos espectrales de señales *staggered* de la presente tesis.

Capítulo 4

Adaptive Spectral Processing for Staggered Signals (ASPASS)

“Una hipótesis puede ser fructífera, no sólo para sus proponentes si no, aún más, para conducir a otros nuevos avances.”

— WILLIAM IAN BEARDMORE BEVERIDGE

4.1. Introducción

Como se describió en la introducción, existe una relación de compromiso en la elección de la PRI: el rango máximo que el radar puede observar tiene una relación proporcional con el PRI, mientras que la velocidad Doppler media máxima que se puede medir posee una relación inversamente proporcional con el PRI [17]. Por lo tanto, al aumentar uno, necesariamente, se reduce el otro. Para lidiar con este problema, en la Sección 2.5 se describió el modo de operación *staggered*, que consiste en alternar pulso a pulso entre más de una PRI (en general dos valores). De este modo, se cuenta con un grado más de libertad, resultando en que el rango máximo mantiene una relación proporcional con los PRIs, pero la velocidad Doppler media máxima posee una relación inversamente proporcional con la diferencia de los PRIs [3].

Desde el punto de vista de la estimación de momentos espectrales (en especial para la velocidad Doppler media), como se mostró en la Sección 2.5, el modo de operación *staggered* resuelve inmediatamente el problema. Sin embargo, la secuencia de muestras que se deben procesar en la dimensión tiempo lento poseen una separación temporal no uniforme. Esto conlleva una dificultad extra al momento de realizar el procesamiento para el filtrado del clutter terrestre. Las herramientas habituales de filtrado y análisis espectral no pueden aplicarse de manera directa [34].

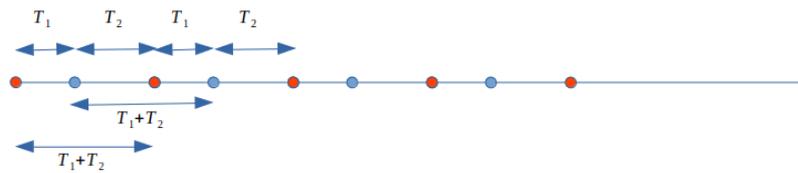


Figura 4.1: Muestreo staggered.

Al igual que para el caso de PRI uniforme, existen dos enfoques para atacar el problema del filtrado de clutter terrestre con PRI *staggered* (PRIS). Una de ellas es la de emplear un filtro fijo. En el caso de PRIS, el muestreo es no uniforme, pero tiene un patrón que se repite periódicamente. Esto permite dividir la secuencia de datos no uniformemente espaciada en dos secuencias con espaciado temporal uniforme, pero mayor al original. Por ejemplo, en el caso de emplear dos PRIs, el tiempo entre muestras de las dos secuencias resultantes es la suma de las PRIs, ver Figura 4.1. Luego, se aplica un filtro notch en la velocidad Doppler cero a cada una de las secuencias obtenidas. Finalmente, la secuencia a la salida de cada filtro se combina de forma conveniente para obtener nuevamente una secuencia con el muestreo no uniforme inicial [74]. En el diseño de los filtros se han empleado del tipo equiripple o métodos de ventanas, arrojando estos últimos mejores resultados [74]. Este tipo de técnicas presenta dificultades cuando el espectro de la señal debida al fenómeno meteorológico posee componentes cercanas a cero, porque son filtradas junto con el clutter. En este caso, a ello se le suma el efecto de replicado que, en general, afecta a la señal debida al fenómeno meteorológico ya que la tasa de muestreo resultante para cada una de las secuencias con espaciado uniforme generadas es baja en comparación con las componentes de frecuencia que posee el fenómeno [75].

La alternativa que reemplaza a los filtros fijos consiste en el uso de las técnicas adaptivas, las cuales además de remover el clutter terrestre, buscan reconstruir el espectro de la señal previo a ser contaminada con clutter. En el modo de operación *staggered*, la técnica GMAP-TD [25], presentada en la Sección 2.4.4 para PRI uniforme, posee una extensión natural para PRIs tal como se describió en la Sección 2.5.3. En este capítulo se introduce y se desarrolla el algoritmo ASPASS propuesto en el marco de esta tesis [41]. El método propuesto es una solución, del tipo adaptiva, al problema de filtrado de clutter terrestre y la estimación de los momentos espectrales para señales adquiridas en modo de operación *staggered*. Trabaja en el dominio del espectro, con una serie de pasos similares a los que utiliza el algoritmo GMAP para PRI uniforme [24], pero teniendo en cuenta las particularidades que presenta el espectro de una secuencia no uniformemente muestreada. Este algoritmo puede ser visto como una generalización de

GMAP para este tipo de secuencias. Cabe remarcar, que si bien el algoritmo puede ser generalizado a cualquier relación de PRIs, sin pérdida de generalidad, en el desarrollo del presente capítulo se utiliza el modo 2/3.

El capítulo está organizado de la siguiente manera. En la Sección 4.2 se desarrollan los pasos del algoritmo. En la Sección 4.3 se estudia el desempeño de ASPASS por medio de simulaciones numéricas de tipo Monte Carlo, empleando datos sintéticos. Se realizan diferentes experimentos, los que consisten en variar alguno de los parámetros del fenómeno, y que, además, contemplan tanto la presencia como la ausencia de clutter terrestre. Como medida de desempeño se considera el sesgo promedio de los estimados y la desviación estándar de los mismos. Por su parte, en la Sección 4.4 se realiza el procesamiento sobre mediciones reales de radar meteorológico, registradas empleando el radar argentino RMA-12. Por último, en la Sección 4.5 se presentan conclusiones.

4.2. Método

El algoritmo Adaptive Spectral Processing for Staggered Signals (ASPASS) opera sobre datos adquiridos en el modo de operación *staggered*, pero comparte el enfoque metodológico con GMAP, que trabaja sobre datos obtenidos con PRI uniforme. Por ese motivo, también se vale de las mismas hipótesis: se considera que la señal recibida se compone de una componente debida al fenómeno meteorológico; una componente debida al clutter terrestre; y una componente de ruido blanco. La distribución de probabilidad de la señal es gaussiana y las señales correspondientes al fenómeno meteorológico y al clutter terrestre se suponen con DEP de forma gaussiana. Asimismo, como es común en este tipo de problemas, el clutter se considera con un ancho espectral conocido, cuyo valor es mucho menor en comparación con el ancho espectral del fenómeno meteorológico.

El hecho de que ASPASS sea análogo a GMAP también conlleva que opere en el dominio de la frecuencia sobre la DEP de la señal adquirida. Sin embargo, en este punto es donde se encuentra su principal diferencia. Las secuencias de datos obtenidas en el modo de operación *staggered* poseen un espaciado temporal no uniforme. Por lo tanto, no es posible aplicar directamente la Transformada Discreta de Fourier, debido a que ésta espera un espaciado temporal uniforme. Para sortear esta dificultad, (teniendo presente que el muestreo no uniforme resultante en la dimensión tiempo lento posee un patrón periódico, donde sus PRI poseen una relación entera) una posibilidad es pensar que subyacente a la grilla temporal no uniforme existe una grilla uniforme, con una PRI de menor valor, para la cual en ciertos instantes no posee muestras de señal asociadas (se suele decir que “se perdieron”). El proceso de asignar el valor cero a las muestras “perdidas”, se conoce como interpolar con ceros. El algoritmo ASPASS opera, justamente, sobre la DEP de la secuencia *staggered* interpolada con ceros, análogamente

a lo que se realiza en [34]. Naturalmente, esta interpolación tiene un efecto sobre el espectro de la señal original, el cual se observará en la siguiente sección.

A partir de la DEP de la secuencia *staggered* interpolada con ceros, ASPASS evalúa una máscara de clutter que le permite identificar las componentes espectrales que pertenecen al mismo y eliminarlas. Posteriormente, emplea un esquema iterativo para reconstruir la DEP del fenómeno, valiéndose de la hipótesis de que posee forma gaussiana. El proceso iterativo de reconstrucción consiste en ajustar una función gaussiana a los datos filtrados, ajuste que se reduce a evaluar los momentos espectrales del fenómeno meteorológico hasta que se satisface un dado criterio de convergencia. El diagrama de flujo que se presenta en la Figura 4.2 resume los pasos del algoritmo, que se enumeran a continuación y que se discuten detalladamente a lo largo de la presente sección:

1. Interpolación con ceros, aplicación de ventana y estimación de la DEP.
2. Filtrado del clutter terrestre. Esta etapa implica la estimación de la potencia de clutter, la determinación de las componentes espectrales del clutter y su eliminación usando una máscara.
3. Estimación de la potencia, la velocidad Doppler media y el ancho del espectro a partir de la autocorrelación obtenida al aplicar la IDFT a la DEP filtrada. Con una primera estimación de los momentos espectrales y usando modelo gaussiano para cada una de las réplicas del fenómeno se reconstruye la DEP luego de ser filtrada. Este procedimiento se repite, reemplazando la DEP reconstruida, hasta que la diferencia de dos estimaciones consecutivas de velocidad y de potencia no superen los $0.005v_a$ y 0.1 dB, respectivamente.

4.2.1. Interpolación con ceros y estimación de la DEP

Sin pérdida de generalidad se supone que la señal adquirida en modo *staggered* emplea dos PRIs, T_1 y T_2 , de relación 2/3, es decir $3T_1 = 2T_2$, tal como se describió en la Sección 2.5.1. Debido a que la señal no se encuentra uniformemente muestreada, no es posible estimar de forma directa su DEP a partir de la DFT. Como alternativa, se propone agregar ceros entre las muestras *staggered*, de forma tal de crear una secuencia uniformemente muestreada, con un período de muestreo $T_u = T_2 - T_1$. La DEP de esta nueva señal, se estima utilizando periodograma [53]. El uso de ventanas en la estimación de la DEP es muy importante para disminuir el efecto de los lóbulos secundarios del clutter, evitando de este modo que enmascaren el espectro del fenómeno meteorológico. En general, la ventana a usar depende de la CSR. Para ASPASS se sugiere emplear ventanas Kaiser, las cuales proporcionan distintos niveles de atenuación de los lóbulos secundarios a partir de un único parámetro α [52].

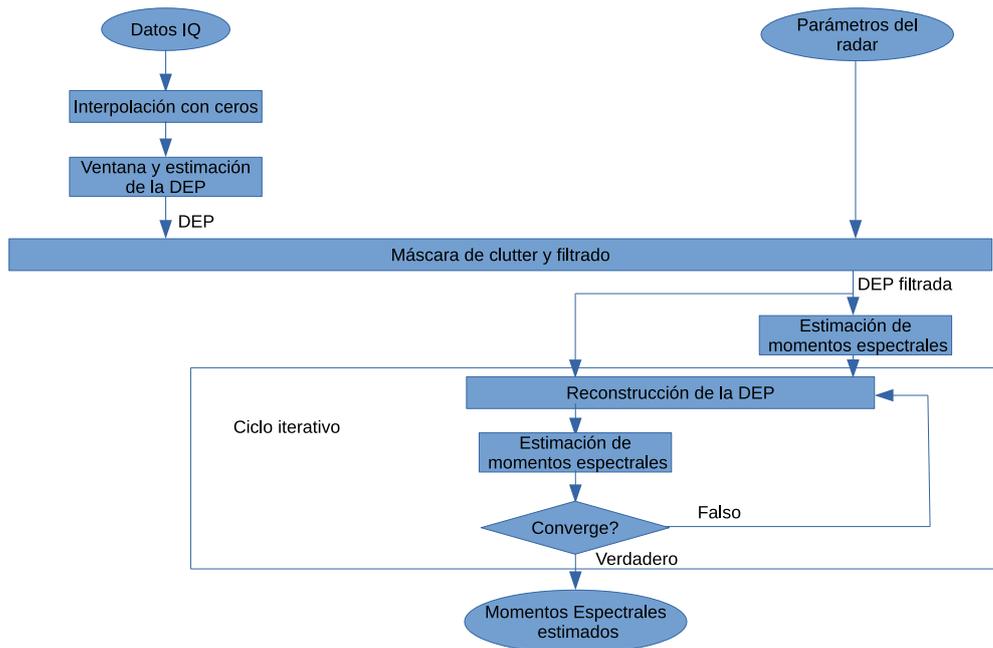


Figura 4.2: Diagrama de flujo de ASPASS.

Como consecuencia de la interpolación con ceros, en la DEP se observan además, del espectro original de la señal, réplicas del espectro del clutter y del fenómeno en determinadas velocidades Doppler, cuyo número y ubicación dependen de la relación T_1/T_2 . Por ejemplo, en el caso $2/3$ aparecen 4 réplicas. Para el clutter terrestre, el espectro original, como es de esperar, se encuentra centrado en velocidad cero y sus réplicas se ubican centradas en las velocidades $\pm 0,4v_a$, $\pm 0,8v_a$. En el caso del fenómeno, el espectro original se encuentra centrado en la velocidad Doppler media del fenómeno v_p y sus réplicas en las velocidades $v_p \pm 0,4v_a$, $v_p \pm 0,8v_a$. La Figura 4.3 muestra la DEP de una secuencia *staggered* $2/3$ de longitud $M = 64$, obtenida a partir de datos sintéticos. En la generación de los datos se consideró la presencia de clutter terrestre, fenómeno meteorológico y ruido. Los parámetros de la simulación son los siguientes: $f_c = 5,6$ GHz, $CSR = 40$ dB, $T_1 = 0,5$ ms, $T_2 = 0,75$ ms, $SNR = 20$ dB, $v_p = 0,4v_a$, $\sigma_p = 3$ m/s, $\sigma_t = 0,3$ m/s (ancho del espectro del clutter teórico). Se utilizó una ventana Kaiser con $\alpha = 8$. En la figura se indican las posiciones de los espectros originales tanto del clutter como del fenómeno. Notar que en la situación elegida, una réplica del clutter se superpone parcialmente con el espectro del fenómeno meteorológico. Este efecto se produce como consecuencia de la interpolación con ceros. A lo largo de la sección se hace referencia a esta simulación para mostrar gráficamente el efecto que producen los diferentes pasos del algoritmo sobre el espectro de la señal.

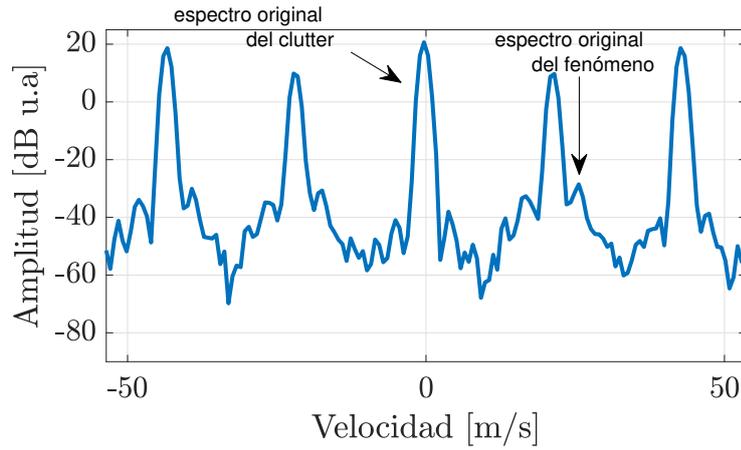


Figura 4.3: DEP estimada de la secuencia *staggered* interpolada con ceros.

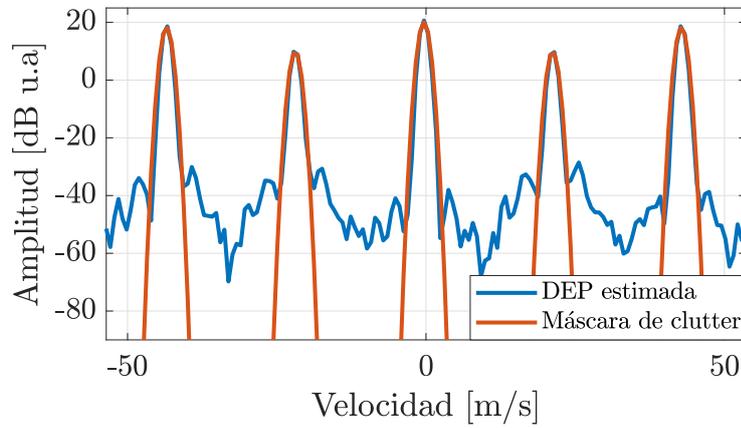


Figura 4.4: DEP estimada y máscara de clutter.

4.2.2. Filtrado del clutter terrestre

Con el objetivo de filtrar el clutter terrestre se construye una máscara, $\text{Mask}(v)$, que servirá para delimitar la región del espectro que posee componentes de clutter. Teniendo en cuenta las particularidades del espectro resultante luego de la interpolación, a diferencia de GMAP, para la relación 2/3, la máscara está conformada por cinco gaussianas, contemplando la correspondiente al espectro original y las cuatro réplicas adicionales del mismo. La deducción de la máscara se encuentra desarrollada en el Apéndice A, su expresión matemática está dada por

$$\text{Mask}(v) = \frac{p_c}{\sqrt{2\pi}\sigma_c} e^{-\frac{v^2}{2\sigma_c^2}} + \frac{\cos^2\left(\frac{2\pi}{5}\right)p_c}{\sqrt{2\pi}\sigma_c} e^{-\frac{(v\pm 0,4v_a)^2}{2\sigma_c^2}} + \frac{\cos^2\left(\frac{4\pi}{5}\right)p_c}{\sqrt{2\pi}\sigma_c} e^{-\frac{(v\pm 0,8v_a)^2}{2\sigma_c^2}}, \quad (4.1)$$

donde p_c es la potencia del espectro original y σ_c es el valor observado del ancho espectral de clutter.

Para construir la máscara de clutter, es necesario conocer p_c y σ_c . El valor observado del ancho espectral del clutter se obtiene teniendo en cuenta su valor teórico y la correc-

ción por la ventana empleada, siguiendo un procedimiento análogo al presentado en la Sección 3.2, pero usando ventana Kaiser [52]. Esta ventana presenta un parámetro α que controla el ensanchamiento del lóbulo principal y la atenuación que sufre el primer lóbulo secundario respecto del lóbulo principal. A mayor valor de α , mayores son el ensanchamiento y la atenuación. En la Figura 4.5 se observa lo antes mencionado.

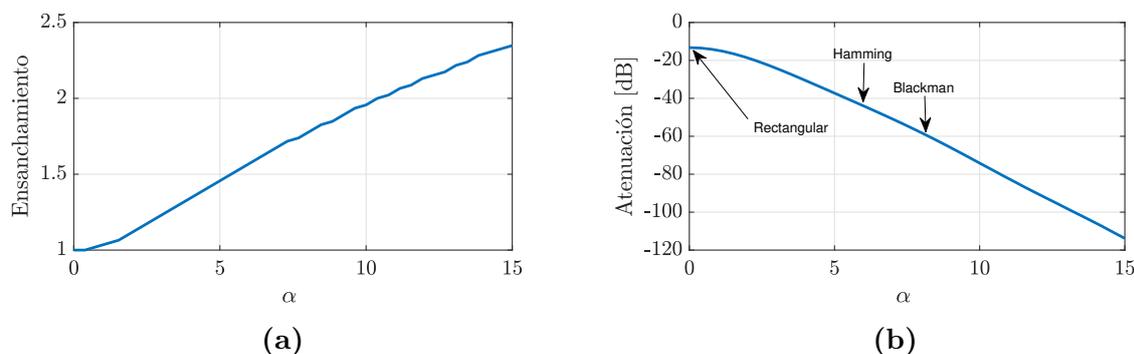


Figura 4.5: Propiedades de la ventana de Kaiser en función del parámetro α . (a) Ensanchamiento relativo del lóbulo principal respecto del obtenido usando la ventana rectangular. (b) Atenuación.

Para estimar p_c se utilizan los tres puntos centrales de la DEP estimada, correspondientes al espectro original del clutter, y se procede de forma análoga a GMAP [24]. La potencia total de clutter, P_c , es igual a la suma de las potencias del espectro original más la potencia de cada una de las réplicas, lo cual se traduce a $P_c = 2,5p_c$. Es importante mencionar que la construcción de la máscara de clutter se realiza de forma dinámica, por lo cual, el algoritmo puede ser empleado en escenarios meteorológicos reales, en los cuales, existen diferentes niveles de potencia del clutter.

La Figura 4.4 muestra la máscara de clutter estimada para la señal descrita en la sección anterior, superpuesta a la DEP de la secuencia *staggered* interpolada con ceros respectiva. Los valores de la DEP correspondientes a las velocidades que quedan por debajo de las gaussianas de la máscara, se identifican como clutter y se eliminan del espectro. En la Figura 4.6 se presenta la DEP filtrada, en la cual se observa el espectro original del fenómeno y sus cuatro réplicas. Los valores faltantes, que se presentan como “huecos” en el espectro, se deben al filtrado. Cabe destacar, que por las implicancias que posee el procesamiento como consecuencia del muestreo no uniforme, no solo se eliminan las muestras en la porción central del espectro, alrededor de la velocidad Doppler 0, sino que también se deben remover las muestras en donde se ubican las réplicas del espectro del clutter.

4.2.3. Estimación de los momentos espectrales

Una vez eliminados los puntos del espectro que corresponden al clutter, lo que se busca es estimar los momentos espectrales del fenómeno meteorológico, que son las

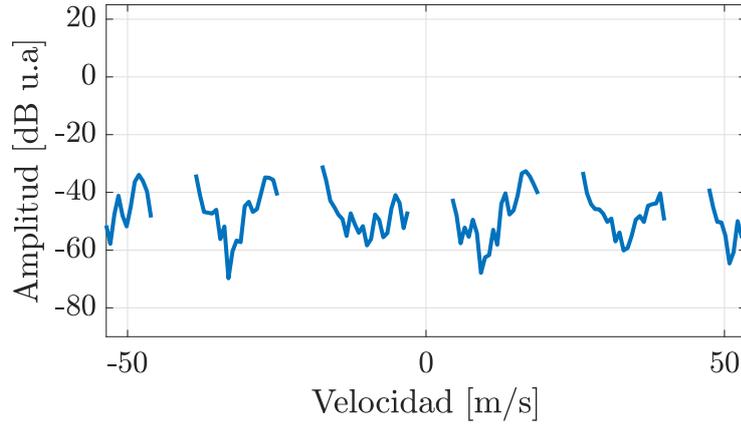


Figura 4.6: DEP filtrada.

variables de interés. Para ello, siguiendo las ideas de las técnicas adaptivas, lo que se propone es reconstruir el espectro del fenómeno meteorológico. A diferencia de GMAP aquí la reconstrucción también involucra reconstruir las réplicas del espectro original. Por lo tanto, al igual que para el clutter, la DEP del fenómeno se modela como la suma de cinco gaussianas de la siguiente forma

$$S_{mp}(v) = \frac{p_p}{\sqrt{2\pi}\sigma_p} e^{-\frac{(v-v_p)^2}{2\sigma_p^2}} + \frac{\cos^2\left(\frac{2\pi}{5}\right)p_p}{\sqrt{2\pi}\sigma_p} e^{-\frac{(v-v_p \pm 0,4v_a)^2}{2\sigma_p^2}} + \frac{\cos^2\left(\frac{4\pi}{5}\right)p_p}{\sqrt{2\pi}\sigma_p} e^{-\frac{(v-v_p \pm 0,8v_a)^2}{2\sigma_p^2}}, \quad (4.2)$$

donde p_p , v_p y σ_p son la potencia del espectro original del fenómeno meteorológico, su velocidad Doppler media y su ancho espectral, respectivamente. Este modelo ajusta bien al espectro real cuando σ_p es tal que no existe superposición significativa entre las réplicas. Aplicando la antitransformada de Fourier a $S_{mp}(v)$ se obtiene la autocorrelación

$$R_{mp}(nT_u) = p_p e^{-\frac{j4\pi v_p nT_u}{\lambda}} e^{-\frac{8\pi^2 \sigma_p^2 (nT_u)^2}{\lambda^2}} \left(1 + \cos^2\left(\frac{2\pi}{5}\right) e^{\frac{\pm j4\pi 0,4v_a nT_u}{\lambda}} + \cos^2\left(\frac{4\pi}{5}\right) e^{\frac{\pm j4\pi 0,8v_a nT_u}{\lambda}} \right), \quad (4.3)$$

con $n = 1, \dots, N$, siendo $N = 5M/2 - 2$ el número de muestras de la señal *staggered* interpolada con ceros. A partir de la fórmula de Euler, la ecuación (4.3) se simplifica a

$$R_{mp}(nT_u) = p_p e^{-\frac{j4\pi v_p nT_u}{\lambda}} e^{-\frac{8\pi^2 \sigma_p^2 (nT_u)^2}{\lambda^2}} \left[1 + 2 \times \cos^2\left(\frac{2\pi}{5}\right) \cos\left(\frac{4\pi 0,4v_a nT_u}{\lambda}\right) + 2 \times \cos^2\left(\frac{4\pi}{5}\right) \cos\left(\frac{4\pi 0,8v_a nT_u}{\lambda}\right) \right]. \quad (4.4)$$

Es importante mencionar que $R_{mp}(t)$ es diferente de la autocorrelación de la señal original, $R_p(t)$. Sin embargo, guardan una estrecha relación en sus valores para los lags $0, T_1, T_2, T_1 + T_2, \dots$. Estrictamente solo difieren por un factor de escala en algunos de

esos lags de interés.

Siguiendo el enfoque de SPPP, pero teniendo en cuentas las particularidades de $R_{mp}(t)$, es posible derivar un conjunto de estimadores de los momentos espectrales, los cuales están dados por

$$\hat{P}_p = \hat{R}_{mp}(0) = 2,5\hat{p}_p, \quad (4.5)$$

$$\hat{v}_p = \frac{\lambda}{4\pi T_u} \arg \left(\frac{\hat{R}_{mp}(T_1)}{\hat{R}_{mp}(T_2)} \right), \quad (4.6)$$

$$\hat{\sigma}_p = \frac{\lambda}{2\sqrt{2}\pi T_1} \sqrt{\ln \left| \frac{\hat{P}_p}{2\hat{R}_{mp}(T_1)} \right|}, \quad (4.7)$$

donde \hat{P}_p , \hat{v}_p , $\hat{\sigma}_p$, \hat{p}_p y $\hat{R}_{mp}(t)$ denotan a los estimadores de P_p , v_p , σ_p , p_p y $R_{mp}(t)$, respectivamente, siendo P_p la potencia total del fenómeno meteorológico.

La expresión del estimador de la velocidad, dada por la ecuación (4.6), es análoga a la obtenida en SPPP. Esta similitud radica en el hecho de que las fases de $R_{mp}(T_1)$ y $R_{mp}(T_2)$ son iguales a las fases de $R_p(T_1)$ y $R_p(T_2)$, respectivamente. Por este motivo, al estimador se lo denominará E-SPPP, donde la letra E hace referencia a “equivalente”. Por otro lado, debido a que depende del cociente de dos estimados de la autocorrelación, al igual que SPPP, su varianza será alta [29]. Razón por la cual, se propone sustituirlo por el estimador que se obtiene del algoritmo DA, descrito en la Sección 2.5.2, usando los estimados de la autocorrelación $\hat{R}_{mp}(T_1)$ y $\hat{R}_{mp}(T_2)$.

Consideraciones respecto del ruido

El piso de la DEP de la señal *staggered* interpolada con ceros, en general, es dominado principalmente por la superposición de las gaussianas de las réplicas del clutter y del fenómeno meteorológico, lo que hace que el ruido sea despreciable para SNR medias a altas. Por este motivo, el efecto del ruido no se tuvo en cuenta en la estimación de los momentos espectrales, el cual dada la dispersión de los estimadores empleados no presenta efectos significativos a menos que la SNR sea baja. Es importante destacar que en general los datos medidos presentan una SNR de 20 dB o mayor [29]. Razón por la cual, a lo largo del capítulo se fijará $SNR = 20$ dB en las simulaciones numéricas. En aquellos casos en que se emplee ASPASS en escenarios de baja SNR (< 10 dB), se recomienda tener presente el efecto del ruido, evaluando su potencia y restando su valor a la estimación de potencia obtenida con la ecuación 4.5. Esto se puede llevar a cabo empleando, por ejemplo, la misma técnica de determinación de nivel de ruido que propone GMAP [54].

Reconstrucción de la DEP del fenómeno

Estimar los momentos a partir del espectro “con huecos” que resulta luego del filtrado, como ejemplifica la Figura 4.6, suele dar estimados muy sesgados. Por lo cual, se propone reconstruir esos valores faltantes a partir de un proceso iterativo sobre la base del modelo gaussiano para la DEP del fenómeno meteorológico. Inicialmente, se realiza una primera estimación de los momentos espectrales usando los estimadores propuestos en la Sección 4.2.3. Luego, se construye la DEP teórica del fenómeno usando la ecuación (4.2). Los valores de la DEP removidos en la etapa de filtrado se sustituyen por los de la DEP teórica. Este procedimiento se repite, hasta que dos estimaciones consecutivas de potencia y de velocidad Doppler media no difieren en más de 0,1 dB y $0,005v_a$, respectivamente. La Figura 4.7 muestra el resultado de las distintas iteraciones en la reconstrucción de la DEP.

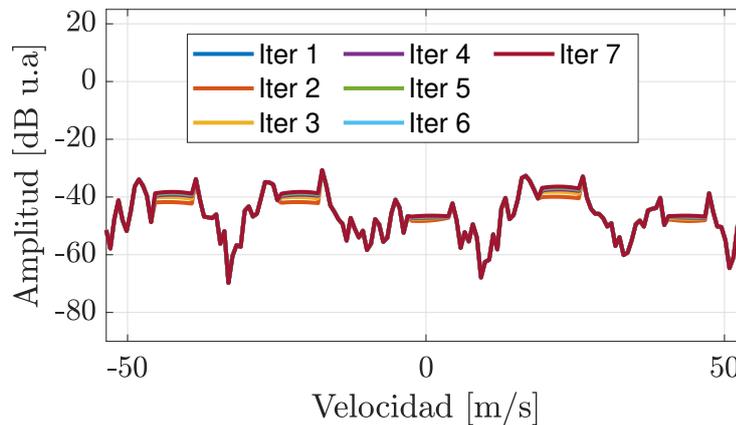


Figura 4.7: DEP del fenómeno meteorológico reconstruida.

4.3. Simulaciones numéricas

Con el propósito de estudiar el desempeño del algoritmo ASPASS se dividió el análisis en dos experiencias. En una primera instancia, se optó por realizar simulaciones numéricas de tipo Monte Carlo. En ellas se busca emular situaciones realistas, donde se respetan los parámetros verdaderos que emplea el radar en operación, pero los datos a procesar se generan de manera sintética, generados a partir de las ideas presentadas en la Sección 2.6, la que respeta la descripción estadística de la que existe evidencia que representa a las mediciones [7]. El recurrir a las simulaciones numéricas permite realizar experimentos controlados, donde se conoce de antemano el resultado esperado y brinda la posibilidad de variar los parámetros de las señales, contemplando todo tipo de situaciones. Asimismo, son de gran utilidad en las etapas de depuración y prueba de las rutinas implementadas.

Las simulaciones numéricas que se presentan fueron divididas en 4 experimentos diferentes, los que permiten evaluar el desempeño de ASPASS tanto en lo que hace a los errores promedio de las estimaciones de los momentos espectrales, como así también en cuanto a su carga computacional. En el primer experimento, se considera la ausencia de clutter terrestre, es decir la señal se compone únicamente de contribuciones de fenómeno meteorológico y ruido, y se estudia el desempeño de los estimadores presentados en la Sección 4.2.3, para diferentes anchos espectrales, σ_p . El segundo, admite la presencia de clutter terrestre y se evalúan los errores de los estimados luego de su filtrado, variando la velocidad Doppler media, v_p , para tres valores de σ_p . En este caso, los resultados se comparan con los obtenidos usando el algoritmo GMAP-TD descrito en la Sección 2.5.3. El tercer experimento consiste en un análisis de tiempos de ejecución de ASPASS en comparación con los tiempos de ejecución de GMAP-TD, en un escenario similar al del tercer experimento. Por último, se estudia el desempeño de ASPASS variando la CSR con el resto de los parámetros fijos en una situación puntual representativa.

Parámetro	Símbolo	Valor
Frecuencia de portadora	F_c [GHz]	5,6
Longitud de onda	λ [cm]	5,35
Relación señal a ruido	SNR [dB]	20
Velocidad Doppler media	v_p [m/s]	0, ..., v_a
Nro. de muestras (pulsos)	M	64
PRI equivalente	T_u [ms]	0.25
Relación entre los PRI <i>staggered</i>	T_1/T_2	2/3
Velocidad máxima no ambigua	v_a [m/s]	53,6

Tabla 4.1: Parámetros para la simulación.

4.3.1. Desempeño en ausencia de clutter terrestre

Debido a que los estimadores que emplea ASPASS poseen ciertas diferencias con los métodos SPPP y DA, presentados en la Sección 2.5, previo a evaluar el desempeño integral de ASPASS se estudia el desempeño de los estimadores propuestos en la Sección 4.2.3. Para ello, en este experimento se contempla que la señal se compone únicamente de contribuciones del fenómeno meteorológico más ruido. Cabe remarcar que para la estimación de la velocidad Doppler media, se utilizan los estimadores E-SPPP, SPPP y DA, y para la estimación del ancho espectral, se usan los estimadores SPPP y el de ASPASS dado por la ecuación (4.7).

Para la simulación se generan datos sintéticos emulando las mediciones del radar en modo de operación *staggered*, cuyos parámetros se encuentran en la Tabla 4.1,

con la salvedad de que se fijó $v_p = 0$ m/s. En total, se emplean 10000 realizaciones de datos para cada valor considerado de σ_p en el rango de 1 m/s hasta 8 m/s. Las métricas elegidas para medir el desempeño de los estimadores son su sesgo promedio y su desviación estándar (std por sus siglas en inglés).

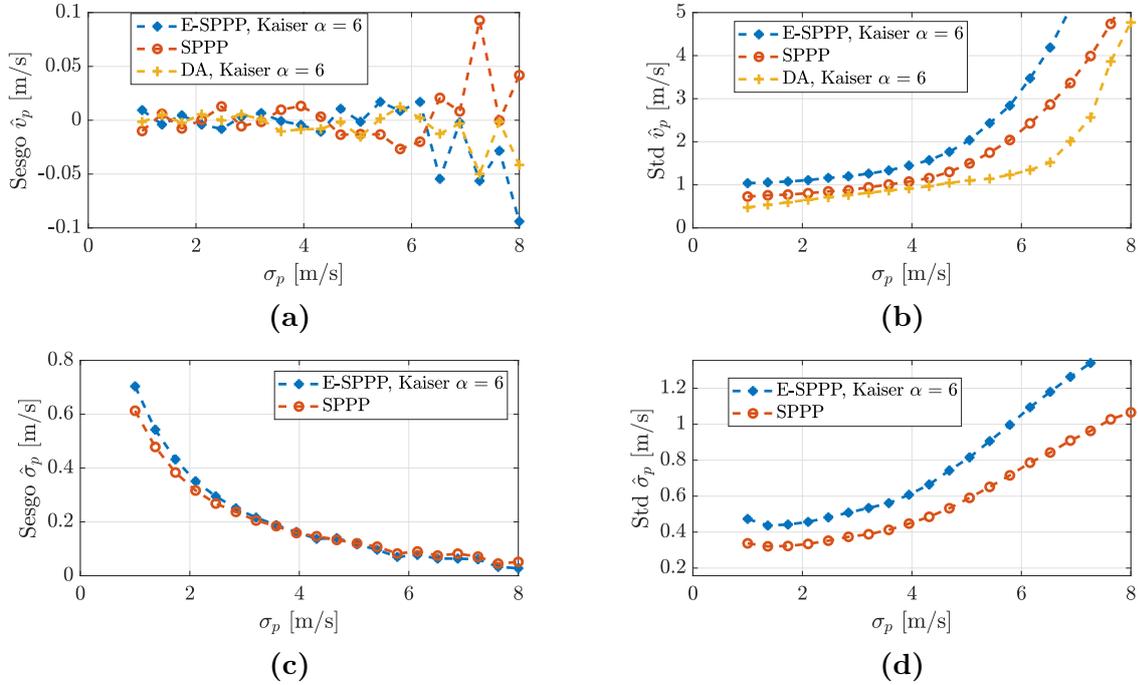


Figura 4.8: Análisis de error. (a) Sesgo promedio de los estimados de la velocidad Doppler media. (b) Desviación estándar de los estimados de la velocidad Doppler media. (c) Sesgo promedio de los estimados del ancho espectral. (d) Desviación estándar de los estimados del ancho espectral.

En la Figura 4.8 se presentan los resultados del análisis para la velocidad y para el ancho espectral. En particular, en la Figura 4.8(a) se muestra el sesgo en los estimados de v_p . Se observa que el sesgo de los tres estimadores presenta un comportamiento similar: su valor oscila alrededor de cero tomando valores muy bajos para anchos espectrales que llegan a 6 m/s y presentan la tendencia a tener un pequeño sesgo de signo negativo para anchos espectrales mayores a 6 m/s. Esto último se explica en el hecho de que cuando el espectro del fenómeno meteorológico es ancho, ocupa gran parte del rango de velocidades, inclusive con efecto de replicado como consecuencia de muestreo, dificultando la estimación de la velocidad. De cualquier manera, los tres estimadores se pueden considerar insesgados desde el punto de vista práctico.

Por otra parte, en la Figura 4.8(b) se muestra la desviación estándar de \hat{v}_p . El comportamiento de la std sigue al del sesgo. La dispersión de los estimados es baja para anchos espectrales inferiores a 6 m/s, incrementándose de manera significativa para valores mayores a 6 m/s. El algoritmo DA presenta el mejor desempeño, es decir para sesgos comparables posee la menor std, lo que era esperable teniendo en cuenta que evita la propagación de errores asociada a evaluar la fase de un cociente de estimados de

la autocorrelación. Estos resultados justifican su elección como estimador de velocidad para ASPASS. Las diferencias en la std entre el algoritmo SPPP y E-SPPP responden a que SPPP no usa una ventana específica, lo que es equivalente a utilizar una ventana rectangular, mientras que para DA y E-SPPP se utiliza ventana Kaiser con $\alpha = 6$ para la estimación de la DEP. Si bien para este experimento el uso de una ventana agresiva como la de Kaiser con $\alpha = 6$ no resulta necesario (porque la señal no posee contribuciones de clutter), se tuvo en cuenta, justamente, para analizar su impacto sobre la estimación de los momentos de interés.

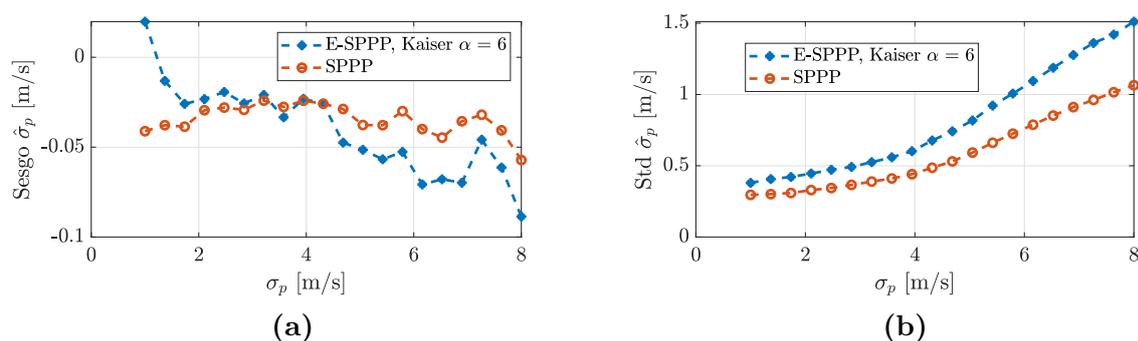


Figura 4.9: Análisis de error de los estimados del ancho espectral cuando se descuenta la potencia de ruido en la estimación. (a) Sesgo promedio. (d) Desviación estándar.

En la Figura 4.8(c) se muestra el sesgo promedio de $\hat{\sigma}_p$. Para ambos estimadores, se observa que la estimación es sesgada y que disminuye a medida que σ_p aumenta. Para explicar este comportamiento se incluyen los resultados de la misma simulación, pero en la que a la autocorrelación en el lag 0 se le descontó el valor de la potencia teórica del ruido. En la Figura 4.9(a) se presenta el sesgo promedio de cada método para esta situación, donde se observa que los mismos son realmente bajos, muy próximos a cero para todo el rango de valores de σ_p . Esto muestra que cuando el ancho espectral del fenómeno meteorológico es angosto el ruido degrada la estimación.

Por su parte, en las Figuras 4.8(d) y 4.9(b) se presentan las std de $\hat{\sigma}_p$ cuando no se descuenta y cuando se descuenta la potencia de ruido en la estimación, respectivamente. El comportamiento de la std es muy similar para ambas situaciones y poseen los mismos órdenes. Se advierte menor dispersión para SPPP en todo el rango de σ_p simulado. La causa de este comportamiento, radica en el uso de ventana Kaiser con $\alpha = 6$ en ASPASS. En general, si no se aplica ventana en la etapa de estimación de la DEP en ASPASS, los resultados de SPPP y el de las ecuaciones (4.6) y (4.7) son los mismos.

Estos resultados parecen contradecir lo planteado en las consideraciones sobre el ruido realizadas para ASPASS en la sección anterior. Sin embargo, esto no es así debido a que la situación planteada en este experimento no representa las condiciones en las que se espera que opere ASPASS. En ausencia de clutter no es necesario aplicar ASPASS. Por otro lado, en presencia de clutter, su espectro y réplicas “levantan”

el nivel de ruido, y como consecuencia la estimación de potencia de ruido por CPI conlleva un error significativo que sesga las estimaciones en mayor medida que no tenerlo en cuenta. Como se verá en el estudio de desempeño con mediciones reales, resulta representativo considerar el rango de anchos espectrales entre 2 y 5 m/s para el fenómeno meteorológico y en ese intervalo los errores son aceptables.

4.3.2. Desempeño en presencia de clutter terrestre

En el segundo experimento se estudia el desempeño de ASPASS en las condiciones de operación para las que fue concebido: el filtrado de clutter, seguido de la estimación de los momentos espectrales. En este caso se generan datos sintéticos de señal recibida por el radar meteorológico, que contemplan la presencia de clutter terrestre más fenómeno meteorológico y ruido. La mayor parte de los parámetros de las simulaciones que conforman este experimento se encuentran en la Tabla 4.1. Además, se fija $CSR = 40$ dB, $P_p = 1$ u.a, $\sigma_t = 0,3$ m/s (ancho espectral teórico del clutter) y se consideran tres valores distintos de σ_p : 3, 4 y 5 m/s. Se emplean 1000 realizaciones de datos para cada valor de v_p y de σ_p .

Los resultados obtenidos con ASPASS se comparan con los resultados de la versión *staggered* de GMAP-TD. Cabe destacar que ASPASS emplea ventana Kaiser con $\alpha = 8$ en la estimación del espectro y también se utiliza esa ventana en la etapa de determinación del nivel de ruido en GMAP-TD, siguiendo las ideas de [54], lo que permite evaluar la matriz de filtrado \mathbf{A}_{mod} dada por la ecuación (2.35).

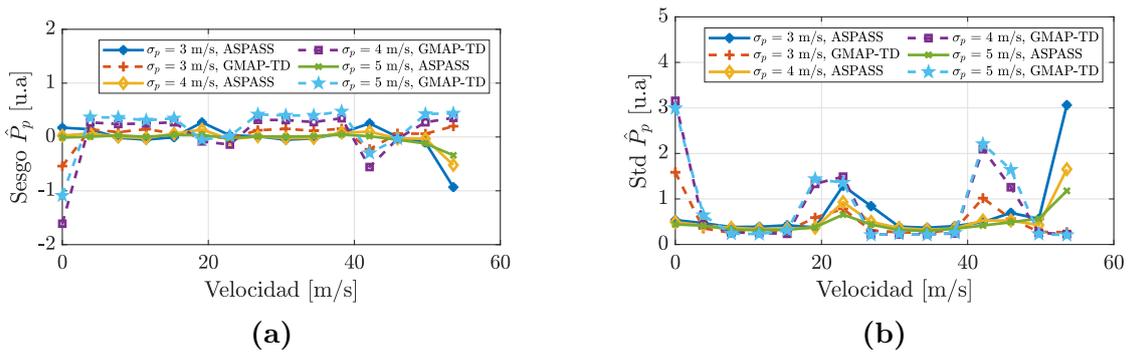


Figura 4.10: Análisis de error en la estimación de potencia del fenómeno meteorológico en presencia de clutter terrestre. (a) Sesgo promedio de los estimados. (b) Desviación estándar de los estimados.

La Figura 4.10 presenta los resultados de la estimación de potencia del fenómeno meteorológico. En la Figura 4.10(a) se observa el sesgo de la estimación. La inspección del sesgo de ASPASS permite destacar que, en general, su valor es próximo a cero en todo el rango de velocidades cuando el ancho espectral toma los valores 4 y 5 m/s. En cambio, para $\sigma_p = 3$ m/s el sesgo es aproximadamente cero solo cuando la velocidad Doppler media del fenómeno meteorológico no cae en la región que corresponde a

alguna de las réplicas de clutter. Notar que, justamente, el sesgo aumenta para los valores de velocidad 0 , $0,4v_a = 21,44$ m/s y $0,8v_a = 42,88$ m/s. Si bien es un efecto que se presenta en todos los casos, el hecho de que sea más significativo para anchos espectrales menores se debe a que al remover el clutter también se remueve gran parte del espectro del fenómeno meteorológico, dificultando su reconstrucción. Cuando σ_p es mayor “sobrevive” una mayor fracción del espectro del fenómeno, lo que favorece su reconstrucción posterior. Sin embargo, es posible afirmar que la estimación de la potencia que realiza ASPASS es insesgada desde el punto de vista práctico.

En el caso de GMAP-TD se aprecia sesgo, el cual aumenta con σ_p . El motivo de este sesgo, radica en la estimación del piso de ruido. Como consecuencia de la superposición de las réplicas tanto del espectro del clutter como de fenómeno meteorológico la estimación del piso de ruido se degrada significativamente, siendo peor a medida que aumenta σ_p .

La desviación estándar presentada en la Figura 4.10(b) permite advertir que ASPASS muestra, en general, un mejor desempeño, es decir menor dispersión, en todo el rango de velocidad y que GMAP-TD presenta un peor desempeño principalmente alrededor de las velocidades en las que se ubican las réplicas del espectro del clutter. Cuando la réplica principal de la DEP del fenómeno se encuentra centrada en la velocidad correspondiente a alguna de las réplicas del clutter, mayor es la porción de la DEP del fenómeno eliminada por el filtrado, siendo de esta forma más difícil su reconstrucción y la correcta estimación de la potencia. Este efecto puede perjudicar a ambos métodos, pero en GMAP-TD además se agrega el hecho de que la matriz del filtro depende del nivel de ruido que se estima con error.

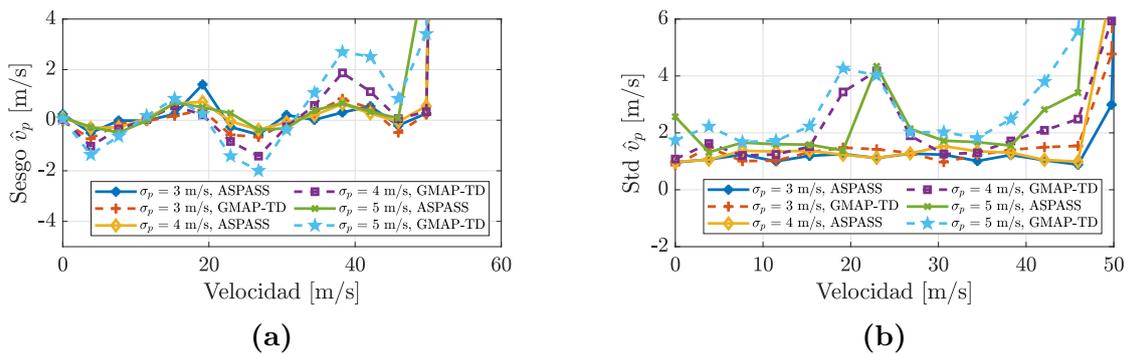


Figura 4.11: Análisis de error en la estimación de velocidad Doppler media del fenómeno meteorológico en presencia de clutter terrestre. (a) Sesgo promedio de los estimados. (b) Desviación estándar de los estimados.

En la Figura 4.11 se presentan los resultados de la estimación de velocidad Doppler media. En la Figura 4.11(a) se muestra el sesgo de los estimados. Se observa que el sesgo promedio de la estimación de velocidad que realiza ASPASS toma valores próximos a cero para todo el rango velocidades y para los tres valores de σ_p estudiados.

En cambio, para GMAP-TD se detecta un sesgo mayor alrededor de las velocidades correspondientes a las réplicas del clutter terrestre. A medida que aumenta σ_p , mayor es el sesgo en los estimados obtenidos con GMAP-TD.

La Figura 4.11(b) corresponde a la std de los estimados de velocidad Doppler media. En el caso de ASPASS se observa que la dispersión se mantiene entre 1 y 2 m/s, en casi todo el rango de velocidades, para σ_p de 3 y 4 m/s. Para $\sigma_p = 5$ m/s el comportamiento es similar salvo, como ocurre con la potencia, en los valores de velocidad $0,4v_a = 21,44$ m/s y $0,8v_a = 42,88$ m/s que es donde se ubican las réplicas del espectro del clutter terrestre. El comportamiento anterior no describe lo que ocurre alrededor de $v_a = 53,6$ m/s, donde, como es de esperar, la dispersión aumenta significativamente como consecuencia del efecto de replicado, allí cuando $v_p \approx v_a$ entonces \hat{v}_p puede tomar valores próximos a v_a o bien a $-v_a$. Pensando en errores relativos, observado los rangos en que la dispersión se mantiene entre 1 y 2 m/s, se puede concluir que son aceptables para velocidades entre 10 y 40 m/s y son elevados fuera de ese intervalo.

GMAP-TD presenta un error comparable al de ASPASS, sin embargo, en general, presenta una dispersión de los estimados ligeramente mayor a los de ASPASS y sufre significativamente el impacto de las réplicas de clutter terrestre cuando el valor de la velocidad Doppler media del fenómeno meteorológico toma valores cercanos a sus ubicaciones. La primera diferencia se debe a que GMAP-TD utiliza SPPP mientras que ASPASS usa DA. La segunda diferencia tiene su origen en el efecto descrito en el análisis de los resultados de la estimación de potencia.

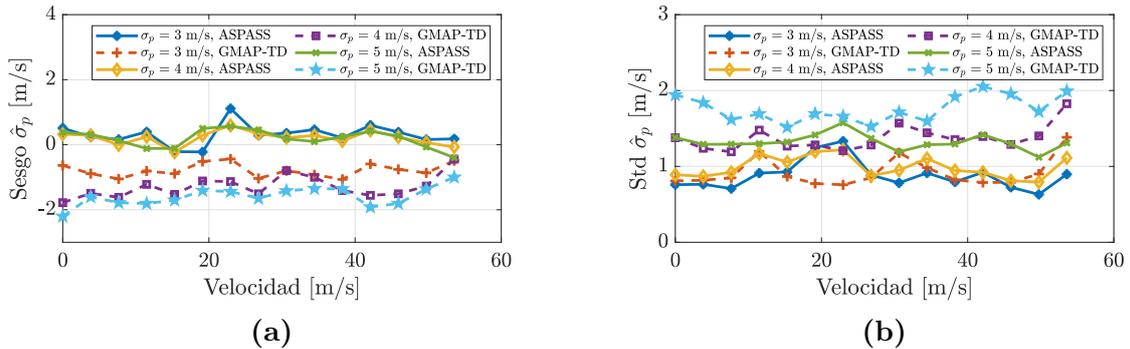


Figura 4.12: Análisis de error en la estimación del ancho del espectro del fenómeno meteorológico en presencia de clutter terrestre. (a) Sesgo promedio de los estimados. (b) Desviación estándar de los estimados.

Finalmente, las Figuras 4.12(a) y 4.12(b) muestran el sesgo y la std de los estimados del ancho espectral, respectivamente. Se aprecia que ASPASS presenta pequeño sesgo alrededor de las velocidades de las réplicas de clutter, aunque de forma general, la estimación se puede considerar insesgada desde el punto de vista práctico. Por su parte, los estimados obtenidos con GMAP-TD poseen un sesgo mayor para todo el intervalo Doppler, que aumenta a medida que σ_p se incrementa.

Con respecto a la std se observa que la dispersión de los estimados, en general, son menores para el caso de ASPASS que para GMAP-TD. Si bien en ambos métodos la dispersión aumenta con σ_p , en el caso de GMAP-TD las diferencias son más importantes. Cabe destacar que ambos métodos presentan un comportamiento poco sensible a las réplicas del clutter terrestre. A diferencia de lo que ocurre con la potencia y la velocidad, no se detectan picos tan pronunciados alrededor de las velocidades en la que se ubican las réplicas del espectro del clutter.

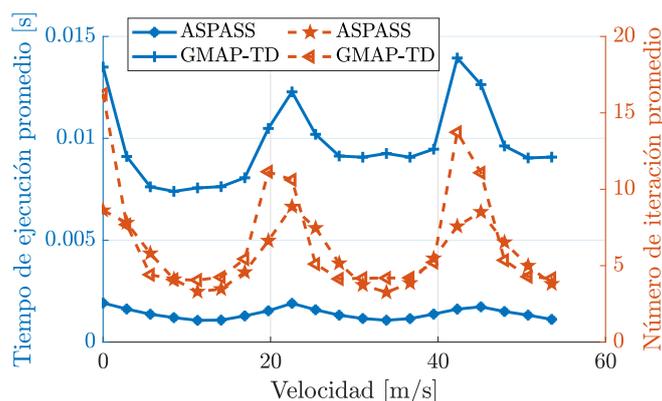


Figura 4.13: Tiempo de ejecución y número de iteraciones de ASPASS y GMAP-TD.

4.3.3. Complejidad computacional de ASPASS

En este tipo de aplicaciones un aspecto importante, además del desempeño desde el punto de vista de los errores, es el costo computacional de los algoritmos de cara a su implementación en un radar operativo. En esta sección se presenta un análisis de la complejidad computacional de ASPASS, y se compara con el respectivo análisis para GMAP-TD. Este estudio se realiza bajo un escenario de simulación específico. Debido a que ambos algoritmos son iterativos, no es sencillo evaluar el número de operaciones requeridas para la convergencia. Por la razón anterior, en el estudio presentado se optó por usar otras dos métricas: el tiempo promedio de ejecución del algoritmo, y el número promedio de iteraciones hasta la convergencia. Para la simulación se consideraron 1000 realizaciones de datos para cada valor de v_p . Como en los casos anteriores, los parámetros generales de la simulación se encuentran en la Tabla 4.1, con $CSR = 40$ dB y $\sigma_p = 4$ m/s. Cabe remarcar que ambos algoritmos fueron implementados en MATLAB, y para la experiencia se emplea una PC con Intel core i7 3770 (3.4 GHz) y 32 GB de memoria RAM.

Los resultados obtenidos se resumen en la Figura 4.13. El eje de las ordenadas sobre el margen izquierdo corresponde al tiempo promedio de ejecución; y el eje de las ordenadas sobre el margen derecho corresponde al número promedio de iteraciones hasta cumplir con los criterios de convergencia. Estos parámetros se encuentran represen-

tados tanto para ASPASS como para GMAP-TD en función de la velocidad Doppler media, v_p .

Por un lado, se observa que el tiempo de ejecución de ASPASS es en promedio 8 veces menor que el tiempo de ejecución de GMAP-TD para todo el intervalo de velocidad Doppler analizado. Como se mencionó en las Secciones 2.4.4 y 2.5.3, el algoritmo GMAP-TD involucra operaciones de multiplicación de matrices y, en especial, de inversión de matrices, lo que hace que posea un costo computacional mayor que el de ASPASS, el que opera en el dominio de la frecuencia, valiéndose de algoritmos eficientes desde el punto de vista del costo computacional, en particular el de la FFT (en inglés, Fast Fourier Transform).

Asimismo, de la Figura 4.13 también se aprecia que en las velocidades correspondientes a las ubicaciones de las réplicas de clutter, ASPASS converge en un número menor de iteraciones. No así para velocidades alejadas de estos valores, donde ambos algoritmos presentan un comportamiento similar en cuanto al número de iteraciones. Es importante notar, que para ASPASS y GMAP-TD, el número de iteraciones para la convergencia aumenta a medida que la velocidad Doppler media se acerca a las velocidades de las réplicas de clutter. Este comportamiento es esperado, debido a que en esas regiones es donde mayor superposición existe entre las DEPs del clutter terrestre y del fenómeno meteorológico.

4.3.4. Desempeño en función de la CSR

Como se ha mencionado a lo largo de la tesis, uno de los problemas que tiene el reducido número de muestras de los CPI es que los lóbulos secundarios que se producen en el espectro del clutter por el truncado temporal de la señal poseen una intensidad significativa en relación a la del espectro del fenómeno meteorológico, llevando en esas situaciones a que se produzca el enmascaramiento de este último. Pesar a las muestras temporales con funciones específicas denominadas ventanas [52] permite reducir los lóbulos secundarios a costa de un ensanchamiento del lóbulo principal del espectro. Las ventanas más agresivas son aquellas que producen una mayor atenuación de los lóbulos secundarios, lo que implica un mayor ensanchamiento del lóbulo principal del espectro con respecto a otras de menor atenuación. Desde el punto de vista de su efecto sobre el espectro del clutter es deseable emplear la ventana más agresiva posible. Sin embargo, esto tiene un impacto sobre el sesgo de los estimadores de los momentos espectrales del fenómeno meteorológico, especialmente sobre el ancho espectral. Por este motivo, a lo largo de esta sección se estudia el uso de las diferentes ventanas que utiliza ASPASS en función de la CSR.

Para la experiencia se consideran 1000 realizaciones de datos sintéticos, cuyos parámetros se encuentran en la Tabla 4.1, y se varía la CSR de 0 a 70 dB. Con el

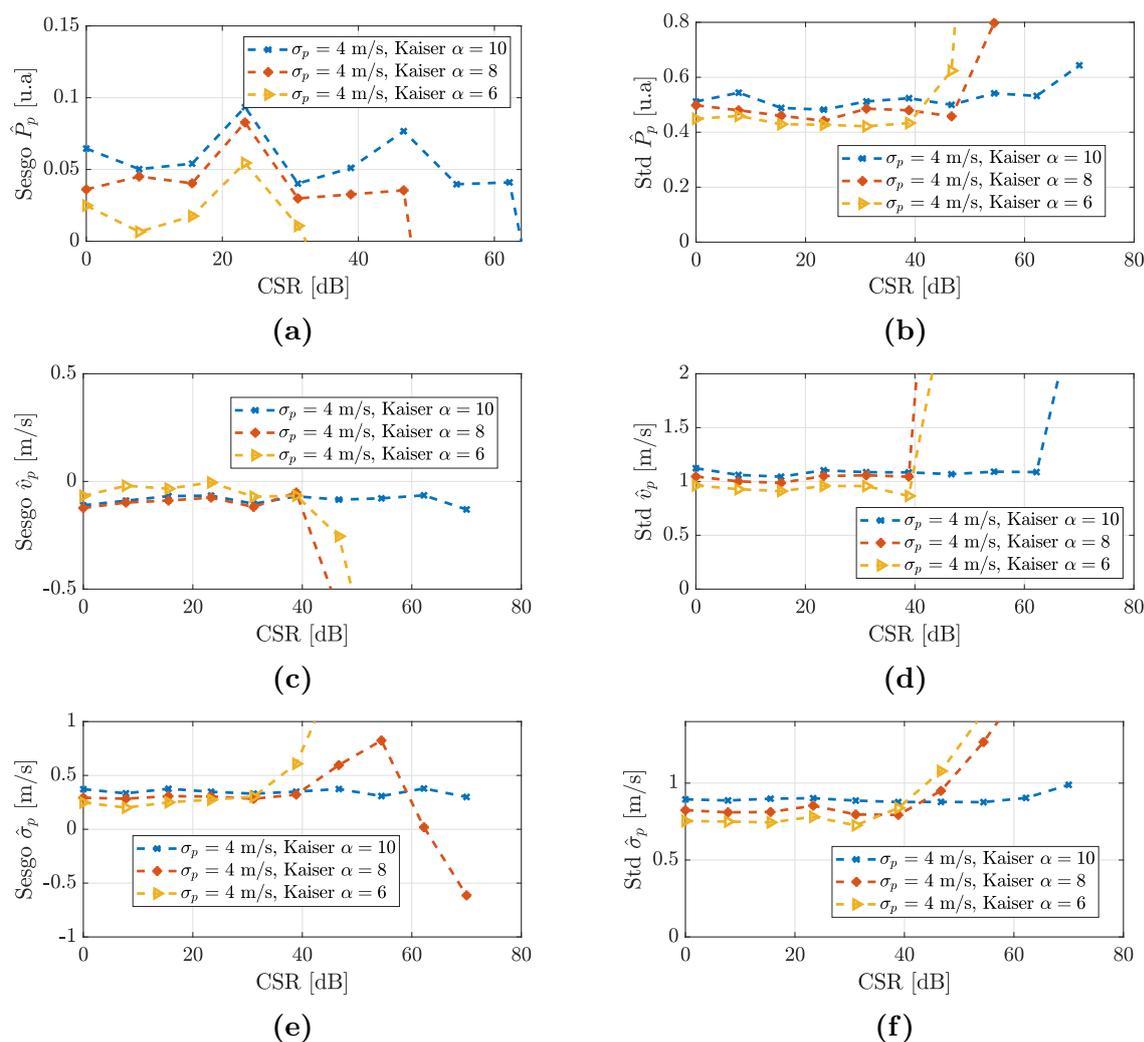


Figura 4.14: Análisis de error variando la CSR. (a) Sesgo promedio de los estimados de potencia. (b) Desviación estándar de los estimados de potencia. (c) Sesgo promedio de los estimados de velocidad Doppler media. (d) Desviación estándar de los estimados de velocidad Doppler media. (e) Sesgo promedio de los estimados del ancho espectral. (f) Desviación estándar de los estimados del ancho espectral.

propósito de considerar una situación desfavorable, el valor de velocidad se mantiene fijo en $v_p = 0,4v_a$, el cual corresponde a la velocidad en la que se centra una de las réplicas del espectro del clutter. Cada realización de datos IQ generados se procesan empleando tres ventanas de Kaiser, las que se obtienen para $\alpha = 6, 8, 10$.

Los resultados del análisis de los errores resultantes para la simulación descrita se presentan en la Figura 4.14. Las Figuras 4.14(a) y 4.14(b) muestran el sesgo y la std de la estimación de potencia en función del valor de CSR, respectivamente; las Figuras 4.14(c) y 4.14(d) muestran el sesgo y la std de la estimación de velocidad Doppler media, respectivamente; y las Figuras 4.14(e) y 4.14(f) se muestran el sesgo y la std de la estimación del ancho espectral, respectivamente.

En primer lugar, se observa que los estimados de los tres momentos espectrales presentan un comportamiento similar. Tanto el sesgo promedio como la desviación

estándar son aproximadamente constantes y del mismo orden para las tres ventanas consideradas hasta cierto valor de CSR, a partir del cual crecen significativamente en módulo. Estos valores de CSR son diferentes para cada ventana considerada. El sesgo promedio y la desviación estándar son aproximadamente constantes hasta: CSR de entre 35 y 40 dB para la ventana Kaiser con $\alpha = 6$; CSR de entre 44 y 56 dB para la ventana Kaiser con $\alpha = 8$; CSR de aproximadamente 65 dB para la ventana Kaiser con $\alpha = 10$. Los valores donde termina cada región donde los errores son constantes, se corresponden aproximadamente con la atenuación del lóbulo secundario de cada ventana [52]. Analizando los errores en términos relativos, tanto el sesgo como la dispersión toman valores mayores para el caso de los estimados del ancho espectral que para la potencia o la velocidad media.

A partir de los resultados obtenidos, como regla general, se propone usar ventana rectangular si $CSR < 5$ dB, ventana Kaiser con $\alpha = 6$ cuando $CSR > 5$ dB y $CSR < 30$ dB, y ventana Kaiser con $\alpha = 8$ si $CSR > 30$ dB y $CSR < 45$ dB. Para valores mayores de CSR se recomienda usar una ventana Kaiser más agresiva. En general, de la Figura 4.14 se concluye que usar ventana agresiva para valores pequeños de CSR está penalizado, pero esa penalización a los fines prácticos no es tan severa como el hecho de que no se renueva parte del espectro del clutter terrestre.

4.4. Datos Reales

La segunda experiencia contemplada en el estudio del desempeño de ASPASS consiste en validar su funcionamiento aplicando el algoritmo a datos reales de radar meteorológico. En esta sección se aplica el algoritmo ASPASS a datos adquiridos con el radar meteorológico RMA-12. Se usan tres conjuntos de datos diferentes, cada uno obtenido con pocos minutos de diferencia entre ellos. El primer conjunto de datos, que en adelante se denomina “conjunto de datos uniforme número 1”, se corresponde a un barrido completo (360°) en el que el radar usa una única PRI de 1 ms, lo cual equivale a una velocidad máxima no ambigua de $v_a = 13,33$ m/s. El segundo conjunto de datos, que en adelante se denomina “conjunto de datos uniforme número 2”, se corresponde a un barrido completo con una única PRI de 0.5 ms, siendo $v_a = 26,66$ m/s. El tercer conjunto de datos, que en adelante se denomina “conjunto de datos *staggered*”, representa un barrido completo empleando PRI *staggered*, con $T_1 = 0,5$ ms y $T_2 = 0,75$ ms, lo cual equivale a $v_a = 53,33$ m/s.

El procesamiento llevado a cabo sobre estos conjuntos de datos tiene por objetivo, en primer lugar, validar el desempeño de ASPASS como filtro de clutter terrestre, y en segundo lugar, verificar el correcto funcionamiento de la etapa de estimación de momentos espectrales. En este último punto la velocidad Doppler media posee un interés especial debido a que la razón de ser del modo de operación *staggered* consiste en poder

resolver velocidades más altas. Por este motivo, la comparación de las estimaciones de velocidad Doppler media resultante de los conjuntos de datos uniformes número 1 y 2 con las estimaciones correspondientes obtenidas a partir del conjunto de datos *staggered* muestra cómo el modo de operación *staggered* permite resolver las velocidades Doppler más altas.

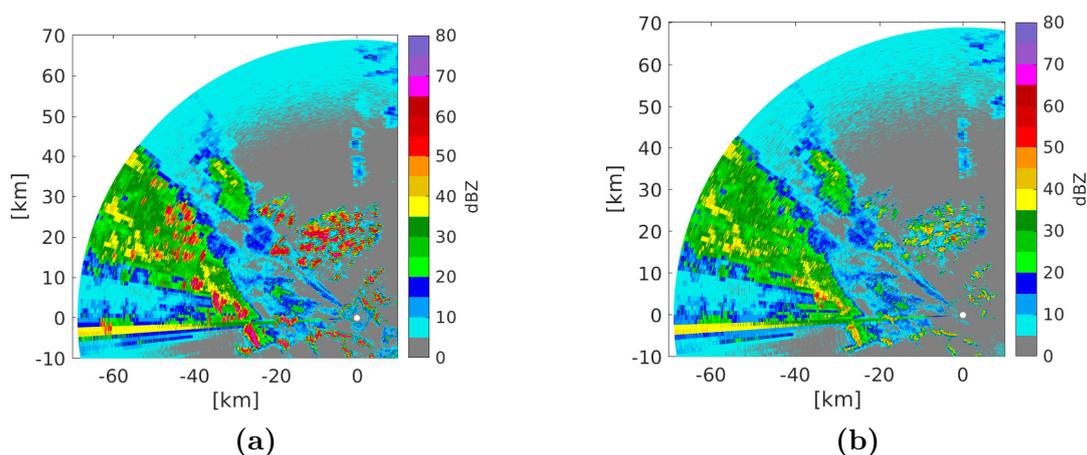


Figura 4.15: PPI de la reflectividad del conjunto de datos *staggered*. (a) Sin aplicar filtro de clutter terrestre. (b) Aplicando ASPASS.

Si bien, como se menciona, se procesaron los barridos completos, los resultados que se presentan a continuación corresponden a aproximadamente un cuarto de cada barrido (90°). El motivo de esta elección radica en que tanto el fenómeno meteorológico como la mayor parte del clutter terrestre se concentran en esa región, lo que permite observar con mayor detalle la zona donde se emplea ASPASS. La convención adoptada para medir los ángulos es la misma que para el sistema cartesiano de coordenadas.

Las Figuras 4.15(a) y 4.15(b) muestran el indicador de posición (PPI por sus siglas en inglés) de la reflectividad correspondiente al conjunto de datos *staggered*, antes y después de aplicar ASPASS, respectivamente. En la Figura 4.15(a) se observan zonas de distintos valores de reflectividad. El clutter terrestre se corresponde a las zonas más intensas ($Z_{hh} > 50$ dBZ), el fenómeno meteorológico a las intensidades medias ($15 < Z_{hh} < 50$ dBZ) y el ruido al resto de valores. A partir del conocimiento geográfico de San Carlos de Bariloche y la ubicación del radar, se identifican algunos cerros populares. Por ejemplo, el cerro Catedral se ubica a una distancia de 25 km y 185° de acimut aproximadamente, el cerro Tronador se encuentra a una distancia de 60 km y 180° de acimut. A una distancia de 25 km y 100° de acimut se identifica una cadena montañosa, la cual, se corresponde a la observada mirando hacia el norte desde el lago Nahuel Huapi. Por último, cabe destacar que alrededor de los 180° existe un pequeño conjunto de muestras de reflectividad que presenta un patrón de “líneas acimutales”. Esto se debe a que la mayor parte de los CPI de todas las celdas de rango en esa dirección se encuentran interferidos por señales correspondientes a redes RLAN/WLAN,

con los que los radares meteorológicos comparten el espectro de transmisión [76]. El resultado de la reflectividad a la salida de ASPASS, que se presenta en la Figura 4.15(b), permite verificar que en líneas generales ASPASS remueve las contribuciones de clutter terrestre. Asimismo, la homogeneidad que presenta la reflectividad alrededor de las zonas donde se removió clutter indican que la estimación de potencia del fenómeno meteorológico luego de la reconstrucción está en los órdenes esperados. Haciendo un análisis minucioso región por región, también se observa que en algunas zonas la eliminación del clutter aparenta no ser completa. En especial para el ángulo acimutal de aproximadamente 170° se observa un pequeño remanente de reflectividad con valores elevados. A continuación se hará foco en esa región para mostrar que el clutter fue removido y que los valores elevados de reflectividad responden a otro efecto.

Con el objetivo de analizar la reflectividad después de aplicar ASPASS, se realiza un estudio detallado observando la DEP en tres regiones distintas que se encuentran a la misma distancia del radar, pero con diferentes ángulos acimutales. De esta forma, si estos últimos no difieren mucho, se garantiza que las tres regiones presenten la misma atenuación y la misma SNR. Cada región se corresponde a un CPI de $M = 64$ muestras. Para todas las estimaciones de densidades espectrales de potencia se usa ventana Kaiser con $\alpha = 8$. La primera región a analizar, que está ubicada aproximadamente a 170° y 35 km, se corresponde a valores altos de reflectividad. La segunda y la tercera región se elijen con ángulos acimutales de 169° y 160° , respectivamente. Las Figuras 4.16(a), 4.16(b) y 4.16(c) muestran la DEP estimada, la máscara de clutter y la reconstrucción de la DEP para la primera región, respectivamente. La Figura 4.16(a) permite observar la presencia de clutter, con su espectro angosto centrado en 0 m/s y sus 4 réplicas debidas a la interpolación con ceros. De la Figura 4.16(b) cabe destacar que la máscara de clutter ajusta bien a su espectro y permite removerlo completamente, tal como se comprueba a partir de la Figura 4.16(c). Por otro lado, el espectro final no permite evidenciar la presencia de fenómeno meteorológico. La velocidad y ancho espectral estimados por ASPASS son $v_p = 38$ m/s y $\sigma_p = 10,9$ m/s. Para la constante de calibración del radar fijada, la reflectividad resultante para este CPI se corresponde a un valor de 65.81 dBZ.

Por su parte, las Figuras 4.17(a), 4.17(b) y 4.17(c) muestran la DEP estimada, la máscara de clutter y la DEP reconstruida para la segunda región, respectivamente. Al igual que en la situación estudiada anteriormente, de la Figura 4.17(a) se observa la presencia de clutter terrestre, lo cual es esperado, ya que este CPI es el adyacente al CPI de la situación previa. De la Figura 4.17(b) se observa la correcta construcción de la máscara de clutter, y en la Figura 4.17(c) se aprecia que el mismo fue removido completamente. En esta ocasión sí se identifica el espectro original del fenómeno alrededor de $v_p = -8$ m/s y con un ancho espectral estimado de $\sigma_p = 6,65$ m/s. Algo importante a destacar es el piso del espectro, el cual, es aproximadamente 35 dB menor que el de

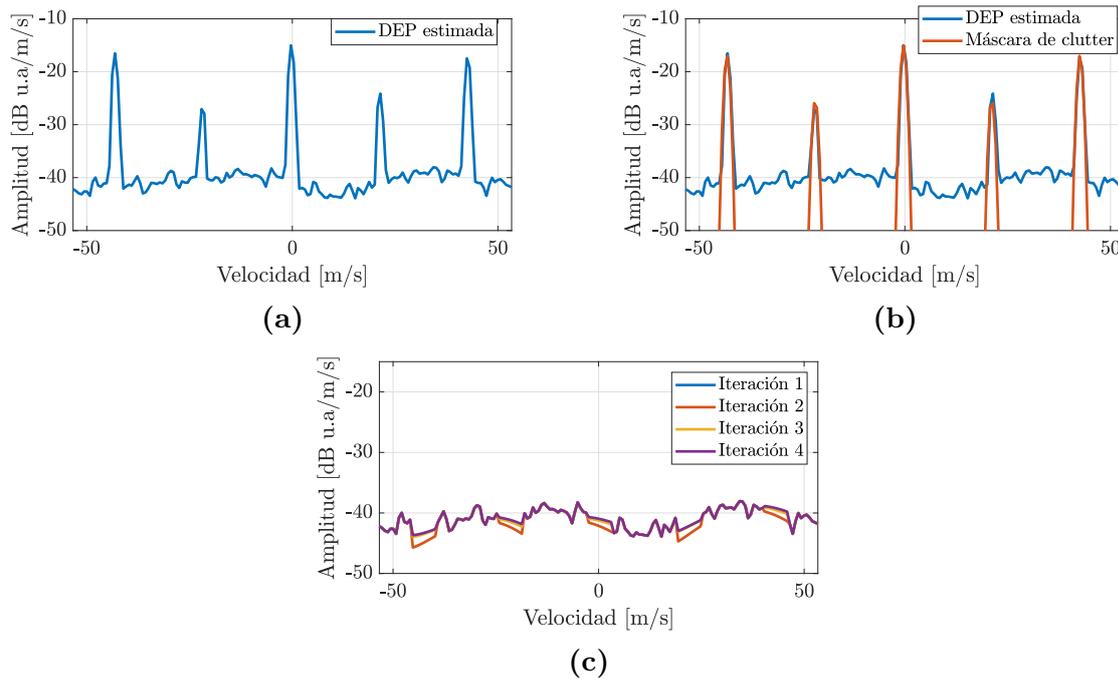


Figura 4.16: Análisis de un CPI de los datos reales de reflectividad alta usando ASPASS. (a) DEP. (b) Máscara de clutter. (c) DEP reconstruida.

la primera región. La reflectividad estimada resultante para este CPI se corresponde a un valor de 30 dBZ.

En la Figura 4.18 se muestra la DEP de la tercera región, en la cual, solo se observa la presencia de fenómeno meteorológico y ruido. En esta ocasión no fue necesario aplicar ASPASS, debido a que no se detectó clutter terrestre. La réplica original del fenómeno se encuentra centrada en $v_p = -18$ m/s y con un ancho espectral de $\sigma_p = 2,2$ m/s. Nuevamente, es importante notar que el piso de ruido se encuentra alrededor de -95 dB u.a./m/s (decibeles por unidades arbitrarias sobre metros por segundo). El valor de reflectividad para este CPI es de 34.8 dBZ.

Este análisis muestra dos cosas. En primer lugar que ASPASS está funcionando como se espera, aún en regiones donde un estudio grueso no permitía verificarlo. Por otro lado, muestra que en las zonas donde el clutter es muy intenso el nivel del espectro es elevado respecto del nivel de ruido en CPI donde no está presente o bien su intensidad es media o baja. Esto lleva a un ocultamiento o enmascaramiento del fenómeno, que no permite observarlo y, además, da como resultado una estimación de potencia mayor a la esperada para esa región, lo que implica una elevada reflectividad. Esto último explica principalmente por qué en algunas regiones de la Figura 4.15(b) queda un remanente de reflectividad elevada aún cuando el clutter fue removido.

En la Figura 4.19 se muestran los PPIs de la velocidad Doppler media para cada conjunto de datos. Las Figuras 4.19(a) y 4.19(b) representan la velocidad Doppler media calculada utilizando PPP sobre los conjuntos de datos uniformes número 1 y 2,

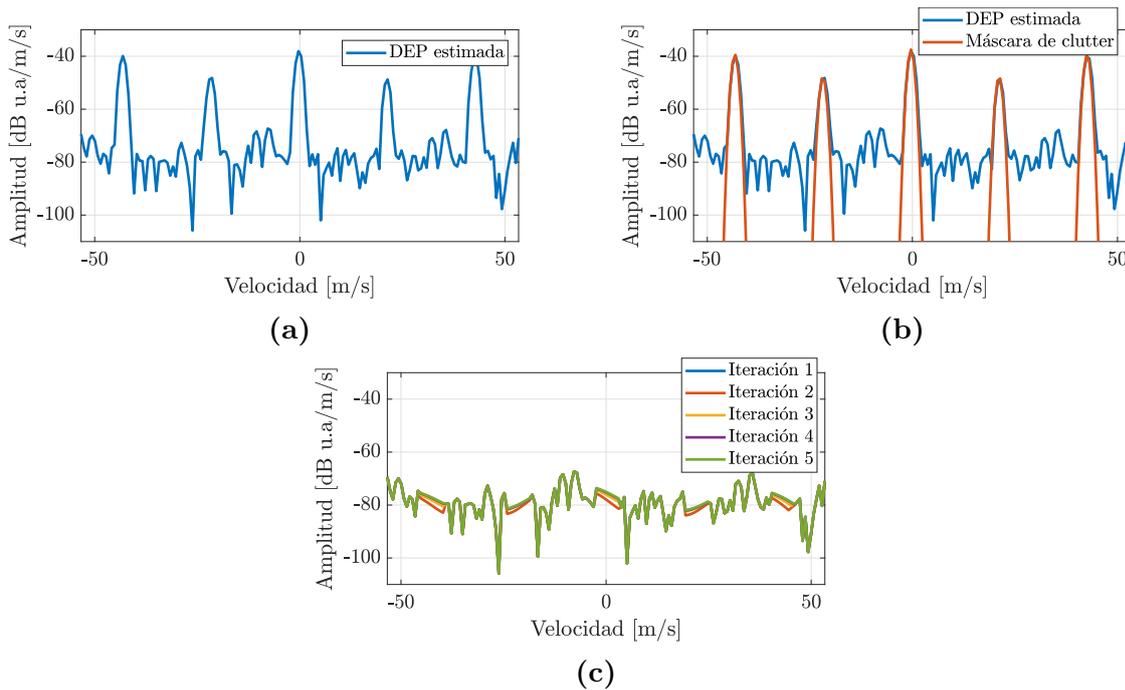


Figura 4.17: Análisis de un CPI de los datos reales de reflectividad media usando ASPASS. (a) DEP. (b) Máscara de clutter. (c) DEP reconstruida.

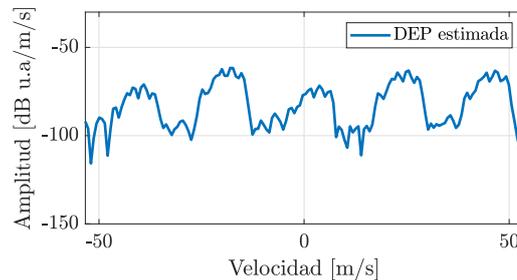


Figura 4.18: Análisis de un CPI de los datos reales donde sólo existe fenómeno y ruido.

respectivamente. En ambas figuras se observa que las zonas identificadas como clutter terrestre en el análisis de reflectividad poseen valores de velocidad en torno a cero, lo que confirma las aseveraciones realizadas. Además, se identifican cambios abruptos en los valores de la velocidad, los cuales van de un extremo del intervalo Doppler hacia el otro (principalmente, pasan de tomar valores cercanos a $-v_a$ a tomar valores de aproximadamente v_a). Debido al tipo de fenómeno meteorológico presente se espera un gradiente de velocidad suave, por ello el comportamiento observado sugiere la existencia de “efecto de replicado” (aliasing en inglés) como consecuencia de que la velocidad máxima no ambigua correspondiente a estos datos es baja para las velocidades Doppler medias que posee el fenómeno observado.

La Figura 4.19(c) muestra la velocidad Doppler media obtenida usando, únicamente, el algoritmo de estimación de velocidad DA sobre el conjunto de datos *staggered*. Notar que las regiones identificadas como clutter, en este PPI también toman valores

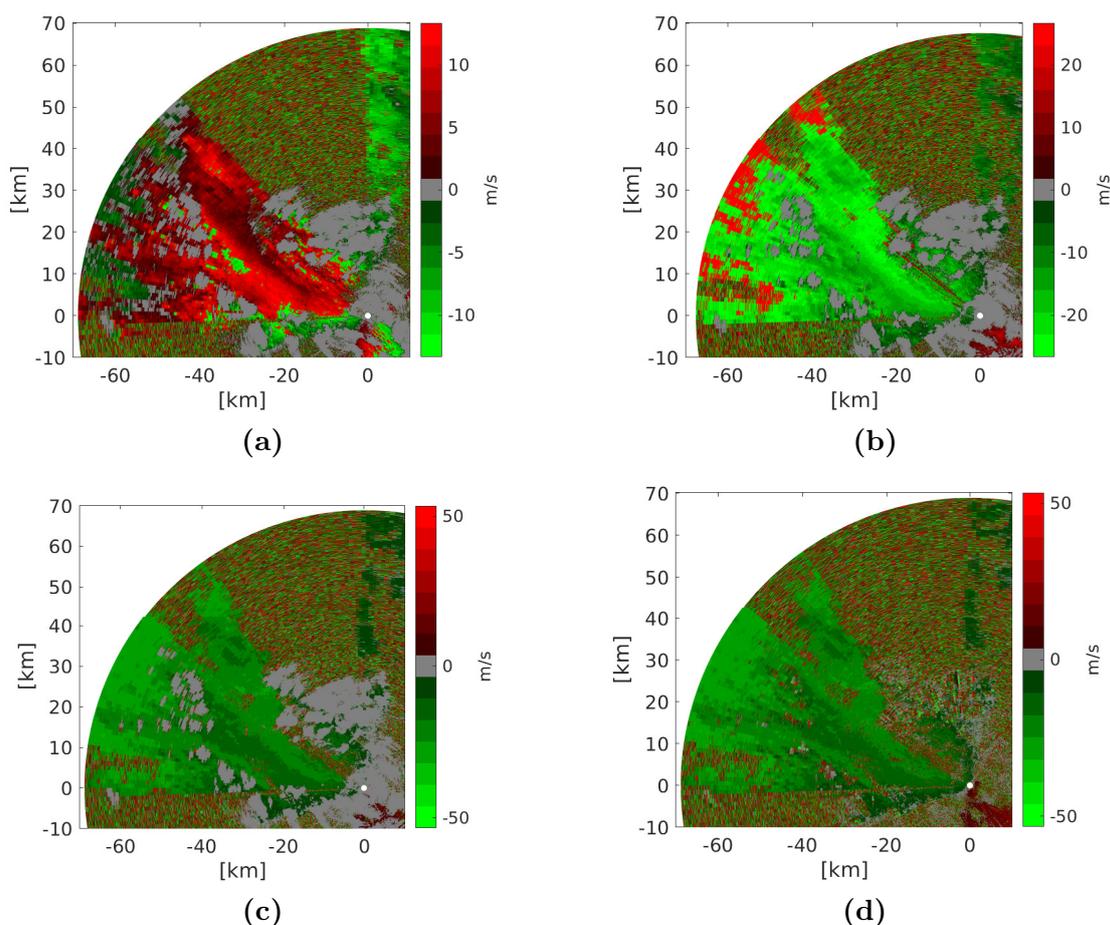


Figura 4.19: PPI de la velocidad Doppler media. (a) Aplicando PPP al conjunto de datos uniforme número 1. (b) Aplicando PPP al conjunto de datos uniforme número 2. (c) Aplicando DA al conjunto de datos *staggered*. (d) Aplicando ASPASS al conjunto de datos *staggered*.

de velocidad alrededor de cero y aproximadamente iguales a los presentados en las Figuras 4.19(a) y 4.19(b). Por otro lado, en estos resultados no se observan cambios abruptos de velocidad, es decir no existe efecto de replicado. Esto es consecuencia de que para el modo de operación *staggered*, la velocidad máxima no ambigua es lo suficientemente alta como para poder resolver la velocidad Doppler media que posee el fenómeno meteorológico en cada región. La Figura 4.19(d) presenta los estimados de la velocidad Doppler media después de aplicar ASPASS sobre el conjunto de datos *staggered*. Como en el caso de la reflectividad, se puede apreciar a simple vista que en las zonas en las que se identificó la existencia de clutter, el mismo fue removido y se recuperó la velocidad del fenómeno meteorológico.

En las Figuras 4.20(a) y 4.20(b) se presentan los PPIs del ancho espectral luego de aplicar SPPP y ASPASS sobre el conjunto de datos *staggered*, respectivamente. De la Figura 4.20(a) se observa que en las regiones donde se identificó la existencia de clutter, debido a que sus contribuciones dominan por sobre las del fenómeno meteorológico y del ruido, los anchos espectrales estimados dan valores bajos, como es de esperar para

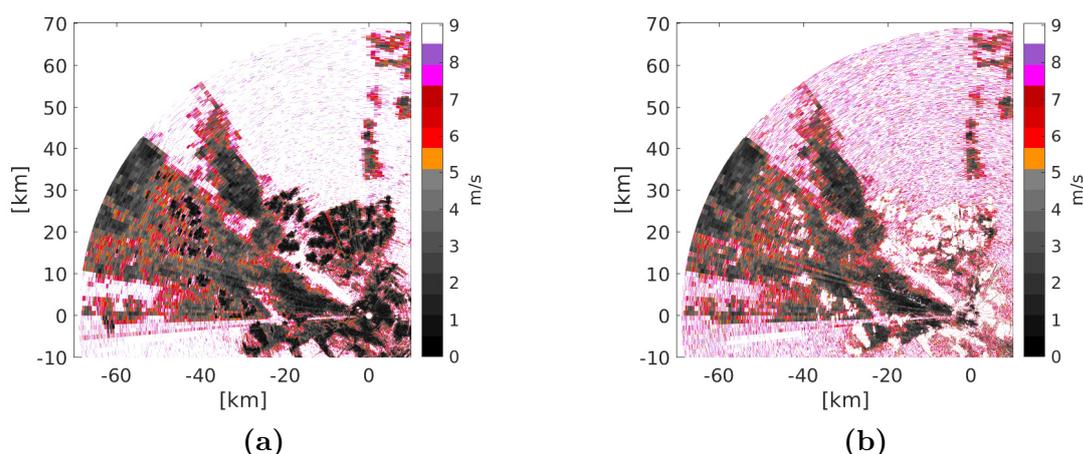


Figura 4.20: PPI del ancho espectral para el conjunto de datos *staggered*. (a) Aplicando SPPP. (b) Aplicando ASPASS.

el clutter terrestre. Por otro lado, en la Figura 4.20(b) se aprecia que el clutter fue removido de las zonas donde estaba presente. Sin embargo, a diferencia de lo que ocurre con la reflectividad y la velocidad Doppler, en este caso la región en torno a estas zonas ya no presenta un comportamiento homogéneo de los valores estimados de ancho espectral. Esto se debe a que el error en la estimación del ancho espectral luego de la etapa de reconstrucción del espectro del fenómeno de ASPASS, presenta un error mayor que para los momentos anteriores. También en estos resultados, se observa claramente que ASPASS remueve el clutter terrestre y los estimados del ancho espectral no toman valores tan bajos, inclusive tienden a ser un poco mayor de lo esperado. Estos resultados se condicen con el desempeño que ASPASS mostró a través de las simulaciones numéricas de la sección anterior. Notar que los estimados del ancho espectral obtenidos con ASPASS en las distintas experiencias en términos relativos presentaron errores por encima de los correspondientes a la potencia y la velocidad Doppler media.

Para finalizar, se concluye que para los datos con los que se ha trabajado el desempeño de ASPASS en general es muy bueno, cumpliendo con los propósitos para los que fue desarrollado. Asimismo, es importante mencionar que en las zonas de clutter terrestre muy intenso, por lo general, la señal de fenómeno meteorológico es muy débil, en ocasiones se da el ocultamiento de sus contribuciones, siendo difícil la estimación de los momentos espectrales en la etapa posterior al filtrado. Este problema no solo lo tiene ASPASS sino que es común a cualquier algoritmo de filtrado de clutter terrestre de su especie.

4.5. Conclusiones

En este capítulo se introdujo el algoritmo ASPASS como una solución al filtrado de clutter terrestre y estimación de los momentos espectrales del fenómeno meteorológico. ASPASS surge inspirado en las ideas del algoritmo GMAP, es decir, puede pensarse como una extensión de este último para señales adquiridas en modo de operación *staggered* del radar. En la primera sección se describieron en detalle los pasos del algoritmo, haciendo especial foco en las particularidades que presenta por lidiar con señales cuya separación temporal no es uniforme.

Una vez presentado el algoritmo se dedicó una gran parte del capítulo al análisis de su desempeño, el que se dividió en dos experiencias. Por un lado, se recurrió a simulaciones numéricas de tipo Monte Carlo, en las que se definieron cuatro experimentos controlados que permitieron estudiar distintos aspectos del algoritmo. Por otro lado, se verificó el desempeño de ASPASS utilizando mediciones reales de radar meteorológico.

Con respecto a las simulaciones numéricas, el primero de los experimentos consistió en estudiar el desempeño de ASPASS cuando la señal se compone solo de contribuciones de fenómeno meteorológico y ruido, es decir sin contribuciones de clutter presentes. Es importante destacar que no está previsto que ASPASS opere en ausencia de clutter terrestre. ASPASS solo filtra el clutter y estima momentos espectrales del fenómeno meteorológico. Por este motivo, se espera que opere de manera conjunta con un clasificador que le de intervención únicamente cuando la señal se compone de clutter terrestre, más fenómeno meteorológico y ruido [14, 77]. En el Capítulo 7 se propone un clasificador empleando la herramienta Deep Learning, el cual puede ser una opción a usar con ASPASS. Más allá de esta aclaración, la importancia del experimento radica en el hecho de que los estimadores de momentos que emplea ASPASS poseen algunas diferencias con los estándar. Los resultados mostraron que los estimadores presentan un buen desempeño en término de errores, comparables al conocido SPPP y, además, permitieron analizar en qué situaciones impacta no conocer el nivel de ruido para SNRs medias a altas.

El segundo experimento consistió en el análisis de desempeño en presencia de clutter terrestre, donde se estudiaron sesgo promedio y desviación estándar de los estimados de los tres momentos espectrales en función de la velocidad Doppler media del fenómeno meteorológico. Asimismo, los errores de ASPASS se compararon con los de GMAP-TD. En líneas generales, ambos métodos presentan un desempeño comparable y ASPASS mostró menor sensibilidad a las réplicas de clutter que se producen por la interpolación con ceros de la secuencia *staggered*. En relación a la estimación de los momentos, los estimados del ancho espectral para ambos algoritmos, presentaron un error mayor en términos relativos para la dispersión.

Por otro lado, se evaluó el costo computacional de ASPASS, también en compa-

ración con GMAP-TD, midiendo tiempos de ejecución y número de iteraciones hasta la convergencia. Para la situación analizada, ASPASS presenta tiempos de ejecución de aproximadamente 8 veces menores que GMAP-TD, aún cuando para algunas velocidades GMAP-TD converge en igual o menor número de iteraciones que ASPASS. La diferencia radica en el hecho de que ASPASS opera en el dominio del espectro, valiéndose de algoritmos eficientes desde el punto de vista del costo computacional, mientras que GMAP-TD opera en el dominio del tiempo involucrando inversión de matrices en el proceso iterativo durante la estimación de los momentos espectrales.

Finalmente, se estudió el efecto de las ventanas sobre el desempeño de ASPASS, el que consistió en medir errores de estimación en función de la relación CSR para tres ventanas Kaiser, manteniendo constantes los demás parámetros de la señal. Este experimento permitió mostrar que los errores se mantienen aproximadamente constantes hasta cierto valor de CSR a partir del cual crecen abruptamente. El valor de CSR que se comporta como un umbral, depende de la ventana considerada y es cercana al valor de atenuación de los lóbulos secundarios de dicha ventana.

Por último, se validó el desempeño de ASPASS utilizando mediciones reales de radar meteorológico adquiridas con el radar argentino RMA-12 ubicado en el aeropuerto de la ciudad de San Carlos de Bariloche. Se procesaron secuencias de datos correspondientes a barridos con PRI uniformes y a barridos con PRIs *staggered* que fueron medidas con una separación temporal de pocos minutos. Esto permitió identificar qué regiones presentan contribuciones de clutter terrestre y permitió observar cómo se resuelve correctamente la velocidad Doppler, aún para valores altos, a partir de emplear la estrategia de operación *staggered*. Asimismo, se verificó que en las regiones correspondientes, ASPASS remueve la componente de clutter terrestre presente y en general realiza una estimación aceptable de los momentos espectrales a partir de la reconstrucción del espectro del fenómeno meteorológico, siendo el ancho espectral el que mayor dispersión presenta, consistentemente con lo que arrojaron los estudios por medio de simulaciones numéricas.

Como trabajo futuro amerita analizar la conjunción de ASPASS con un método de determinación de ruido que opere por radial [78]. Cuando los anchos espectrales son bajos los errores en su estimación se incrementan. Sin embargo, las estrategias de determinación de nivel de ruido empleadas a lo largo de la tesis operan por CPI, lo que produce una estimación del nivel de ruido muy sesgada en aquellos CPI en los que se espera que opere ASPASS, es decir los CPIs contaminados con clutter, como consecuencia de la intensidad de los lóbulos secundarios del espectro del clutter y sus réplicas. Es de esperar mejoras adicionales en el desempeño si se cuenta con una estimación confiable del nivel de ruido y además eso extendería su utilización a situaciones de SNR menores a 20 dB.

Capítulo 5

Procesamiento Doppler empleando aprendizaje profundo

“Si buscas resultados distintos no hagas siempre lo mismo.”

— ALBERT EINSTEIN

5.1. Introducción

Como consecuencia de la disponibilidad masiva de información que existe hoy en día, dando lugar al surgimiento de grandes bases de datos, y del desarrollo de poder de cómputo, las técnicas de machine learning, y en especial, las de deep learning están siendo ampliamente utilizadas en muchos campos de la investigación científica. Por ejemplo: en diagnóstico médico [79] para la clasificación de diferentes tipos de cáncer a través de imágenes médicas; en el descubrimiento y síntesis de medicamentos [80]; en la ingeniería financiera [81], en el manejo autónomo de autos [82], entre otros. Por su parte, también se han usado en el procesamiento de las señales de los radares meteorológicos [83–85]. En [83], se identifican diferentes tipos de clutter (terrestre, marítimo y propagación anómala) mediante la combinación de diferentes parámetros polarimétricos, y el uso de técnicas como: support vector machine, neural networks, decision tree y nearest-neighbour. Los resultados de aplicar estas técnicas son comparables en desempeño a los obtenidos empleando lógica difusa [86] y clasificadores Bayesianos [58]. Recientemente, se propuso un clasificador de tipo de hidrometeoro (lluvia fuerte, nieve, granizo) usando deep learning y lógica difusa [84]. Como modelo, se usa una red neuronal convolucional de varias capas. La misma es entrenada utilizando información polarimétrica [8] de la señal radar, a partir de los productos: reflectividad horizontal, reflectividad diferencial, diferencia de propagación de fase, y el coeficiente de correlación cruzada. Este algoritmo fue evaluado a partir de mediciones del radar polarimétrico WSR-98D/XD,

obteniéndose resultados satisfactorios.

En este capítulo se introduce y desarrolla un nuevo método propuesto en el marco de esta tesis [42]. El mismo consiste en el uso de una DNN para estimar los momentos espectrales de los fenómenos meteorológicos cuando el radar opera con PRI uniforme. La DNN se diseña con tres ramas: la primera para la estimación de CSR, la segunda para la estimación de velocidad Doppler media, y la tercera para la estimación del ancho espectral. Una de sus ventajas consiste en que es un método que opera tanto en escenarios con presencia de clutter terrestre como en su ausencia, realiza una clasificación implícita que le permite adaptarse a cualquiera de los escenarios.

Con el objetivo de elegir una arquitectura que se adecue al problema, se realizó un estudio usando redes densas, en el cual se varía el número de capas ocultas y de neuronas por capa, y se mide el desempeño sobre los datos de validación. Por otra parte, para el entrenamiento se emplean datos sintéticos, contemplando una gran variedad de escenarios meteorológicos posibles (diferentes valores de CSR , SNR , v_p y σ_p).

Para analizar el desempeño de la DNN entrenada, por un lado, se usan simulaciones numéricas de tipo Monte Carlo tomando el sesgo y la desviación estándar de los estimadores de los momentos espectrales como métricas. Además, se compara el desempeño de la DNN con otros métodos: PPP, para el caso de ausencia de clutter terrestre; y GMAP en las situaciones donde el clutter contamina la señal meteorológica. En segundo lugar, se usa la DNN en el procesamiento de datos reales del radar meteorológico RMA-12. En ambas experiencias los resultados obtenidos son comparables a los de los métodos PPP y GMAP, demostrando de esta forma la capacidad de la DNN de abordar distintos escenarios por sí sola. Una vez entrenada, la DNN posee una carga computacional moderada y presenta la característica de procesar miles de celdas de rango al mismo tiempo. De esta forma el método propuesto es un buen candidato para implementaciones en tiempo real.

El capítulo está organizado de la siguiente manera. En la Sección 5.2 se formula el problema, se presenta el método, la generación de los datos de entrenamiento y de validación. En la Sección 5.3 se realiza el estudio para elegir la arquitectura que mejor desempeño presente a partir de los datos de validación. En la Sección 5.4 se analiza el desempeño del modelo entrenado, de forma comparativa con otros algoritmos existentes. El procesamiento de datos reales usando la DNN, se presenta en la Sección 5.5. Finalmente, en la Sección 5.6 se presentan conclusiones.

5.2. Formulación del problema

Como se mencionó en la Sección 2.3.1, el modelo generalmente adoptado para la DEP de la señal meteorológica presenta una estructura bien definida [3]: para el clutter terrestre se considera con forma gaussiana, centrada en velocidad Doppler cero y

varianza σ_c^2 ; para el fenómeno también se modela con forma gaussiana, pero centrada en la velocidad Doppler v_p y varianza σ_p^2 ; y para el ruido se supone constante. A partir de esta estructura, dada una DEP, para ciertos valores de CSR y SNR el ser humano puede inferir si en el registro de datos existen contribuciones de clutter y/o de fenómeno presentes, y además, cual es aproximadamente la velocidad Doppler media de este último. Con el objetivo de ilustrar estas ideas, la Figura 5.1 muestra ejemplos de densidades espectrales de potencia. Cada uno de los cuatro paneles se corresponde a una DEP estimada a partir de la generación de datos sintéticos, cuyos parámetros generales de simulación son: $v_a \approx 26,8$ m/s, $\sigma_t = 0,25$ m/s, $M = 64$ y $SNR = 20$ dB. En la descripción de cada panel se presenta la información específica de los parámetros correspondientes al fenómeno y al clutter terrestre.

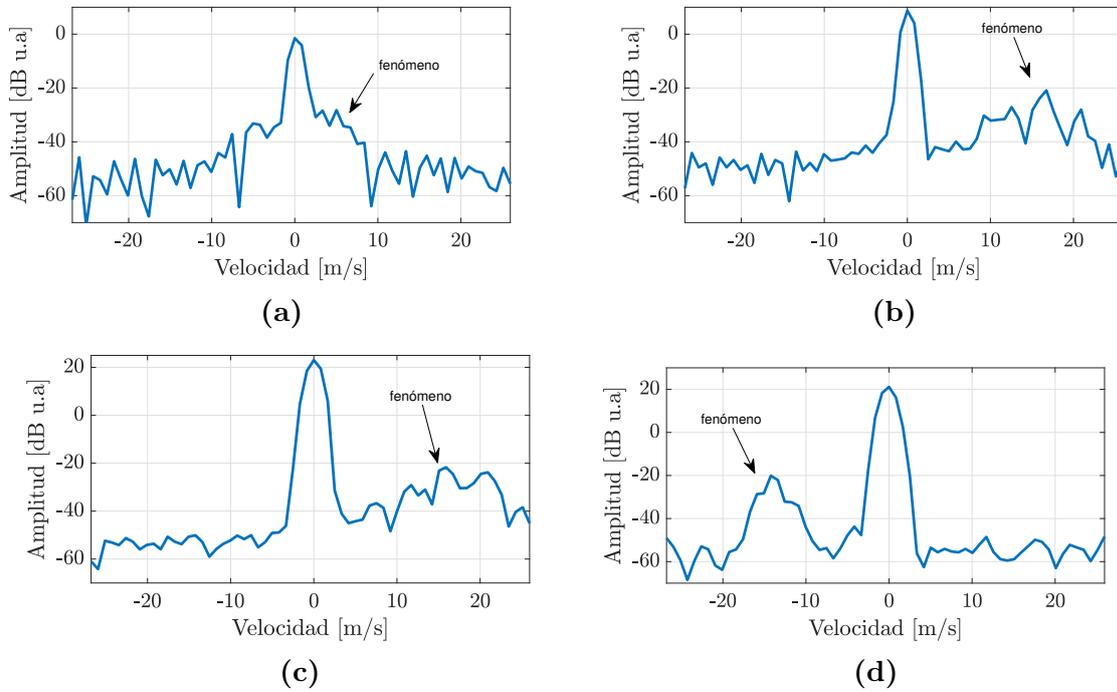


Figura 5.1: Ejemplo de DEPs. (a) $v_p = 0$ m/s, $\sigma_p = 3$ m/s, $CSR = 20$ dB. (b) $v_p = 16$ m/s, $\sigma_p = 3$ m/s, $CSR = 20$ dB. (c) $v_p = 16$ m/s, $\sigma_p = 3$ m/s, $CSR = 40$ dB. (d) $v_p = -13,4$ m/s, $\sigma_p = 1$ m/s, $CSR = 40$ dB.

El razonamiento anterior permite pensar que si somos capaces de estimar la velocidad del fenómeno, con un cierto error, por simple inspección, a partir de observar la DEP; entonces, una red neuronal debidamente entrenada lograría este propósito de forma más eficiente. La misma, puede procesar miles de DEPs en fracciones de segundos, lo cual, es imposible para un ser humano. La red neuronal, además de la velocidad del fenómeno, es capaz de identificar cambios en su ancho espectral y en la relación de potencias entre el clutter y el fenómeno.

El objetivo es diseñar, entrenar y evaluar el desempeño de una red neuronal profunda, la cual se usa para la estimación de los momentos espectrales de los fenómenos

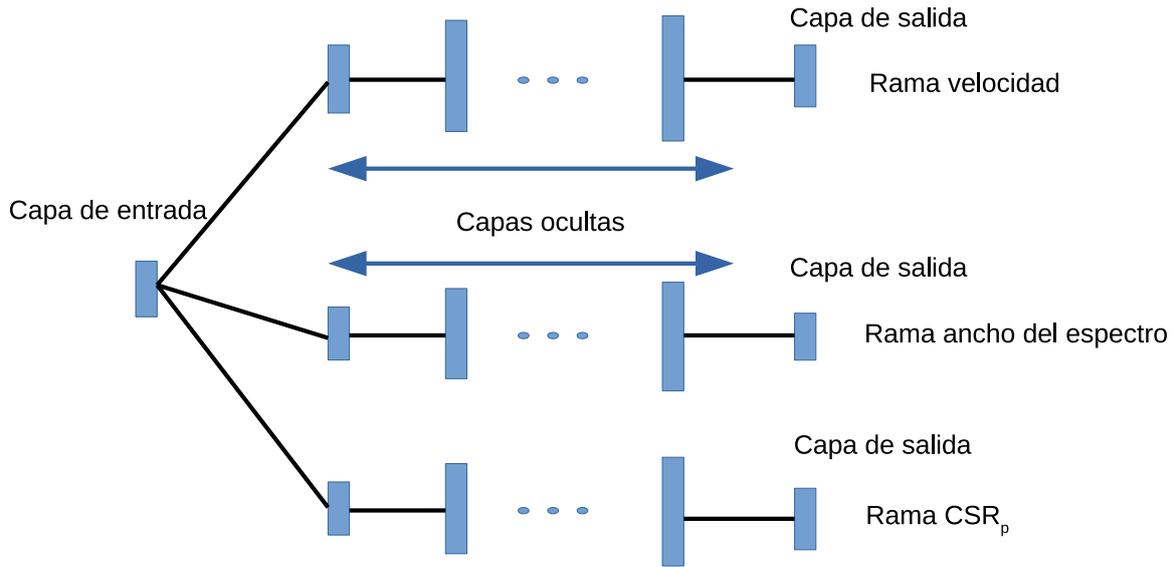


Figura 5.2: Arquitectura general de la red neuronal.

meteorológicos: potencia, p_p ; velocidad Doppler media, v_p ; y el ancho espectral, σ_p .

5.2.1. Descripción del algoritmo

Se propone una red neuronal con tres ramas: la primera para la estimación de la CSR, la segunda para la estimación de velocidad, y la tercera para la estimación del ancho espectral. Se usa un esquema de clasificación, en el cual para cada rama se asigna un número determinado de clases de salida. Estos números se denotan como $N_o^{CSR_p}$, $N_o^{v_p}$ y $N_o^{\sigma_p}$ para las ramas CSR_p , v_p y σ_p , respectivamente. Las clases de salida son valores que surgen de discretizar intervalos de valores esperables para CSR , v_p y σ_p , de modo que la red determine cual es el más cercano para la entrada dada. Por ejemplo, en el caso de la rama de velocidad se toman $N_o^{v_p}$ valores dentro del rango de velocidad Doppler no ambiguo. La Figura 5.2 muestra el diagrama general de la red neuronal, en el que se observan las tres ramas mencionadas. Los números de capas ocultas y de neuronas por capa se definen cuando se estudia la arquitectura de la red en la Sección 5.3.

Se toma como entrada a la red una estimación de la DEP de la señal meteorológica, normalizada respecto de su valor máximo y expresada en escala logarítmica. En su estimación se usa ventana de Blackman con el objetivo de disminuir los lóbulos secundarios del clutter, si el mismo estuviese presente. La Figura 5.3 muestra el diagrama de flujo del método propuesto para obtener los momentos espectrales. Inicialmente, la DEP se estima y se pasa como entrada a la DNN. Las estimaciones de velocidad Doppler media y del ancho espectral son obtenidas en la salida de la red, como la clase seleccionada

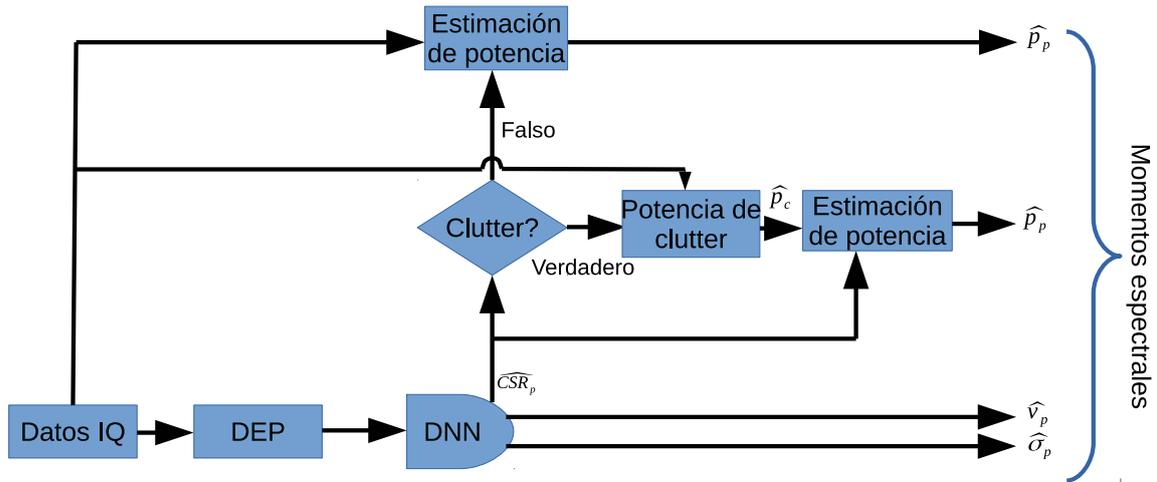


Figura 5.3: Diagrama de flujo usando DNN.

por la red en las ramas correspondientes. En cambio, la potencia se estima de manera indirecta y es necesario identificar previamente la existencia de clutter terrestre. Se declara que existe clutter terrestre cuando $\widehat{CSR}_p \geq 0$. En estas condiciones, la clase de salida de la rama de CSR brinda el estimado \widehat{CSR}_p . Luego, la potencia del fenómeno se estima como $\hat{p}_p = \hat{P}_c 10^{-\widehat{CSR}_p/10}$, siendo \hat{p}_c la estimación de potencia del clutter, que se realiza a partir los tres puntos centrales de la DEP, como se explicó en la Sección 2.4.3 para el algoritmo GMAP. Por otro lado, si se declara que no existen contribuciones de clutter presente, p_p es estimada como $\hat{p}_p = \hat{R}(0) - \hat{P}_n$, donde $\hat{R}(0)$ y \hat{P}_n son las estimaciones de la autocorrelación de la señal recibida evaluada en el instante cero y la potencia de ruido, respectivamente.

5.2.2. Generación de los datos de entrenamiento y validación

Debido a la dificultad de recolectar datos reales bien etiquetados, para diferentes configuraciones meteorológicas, se propone usar datos sintéticos para entrenar y validar la red. Este procedimiento se sustenta en el hecho de que el modelo utilizado para la señal se ajusta bien a las mediciones de los radares meteorológicos [7]. De esta manera, se puede recrear muchos escenarios meteorológicos variando los diferentes parámetros del modelo de datos para el clutter, el fenómeno y el ruido. Además, permite utilizar varias realizaciones para una misma condición meteorológica. Esto último es importante, ya que la DEP estimada a partir de los datos IQ presenta incertidumbre debido a su naturaleza aleatoria. Entonces, considerando un rango amplio de variación de los parámetros meteorológicos de forma tal de sintetizar la mayor parte de las situaciones

de interés, se obtienen los conjuntos de datos de entrenamiento y validación.

Un parámetro importante a tener en cuenta es el ancho del clutter teórico σ_t , el cual, como se mencionó en la Sección 3.2, depende de las características de la antena y del número de pulsos dentro del CPI. Teniendo esto en cuenta, y debido a que en la Sección 5.5 se usa la red entrenada para procesar datos reales del radar RMA-12, entonces se fija su valor a partir de lo esperado para esos datos: $\sigma_t = \frac{2\sqrt{\ln 2}}{\pi M} v_a \approx 0,01 v_a$. Esto no representa una restricción del método. Cuando se utiliza un radar diferente u otra configuración de operación, solo será necesario entrenar la red usando datos sintéticos que contemplen el nuevo valor de σ_t .

Se divide el espacio de parámetros en una grilla tetradimensional, que contempla la mayor cantidad de valores de interés con una separación razonable entre ellos. Cada dimensión corresponde a uno de los siguientes parámetros: CSR , SNR , v_p y σ_p . Para CSR , se eligen 25 valores separados uniformemente en el intervalo de 0 dB a 50 dB. Además, se incluye la situación donde no existe clutter terrestre ($CSR \rightarrow -\infty$), conformando un total de $N_o^{CSR_p} = 26$ clases para la CSR . Para SNR se eligen 15 elementos uniformemente espaciadas en el intervalo 0 dB a 30 dB. En el caso de σ_p se eligen $N_o^{\sigma_p} = 12$ clases, en el rango de $0,04v_a$ a $0,4v_a$. Para v_p se usa una grilla de $N_o^{v_p} = 40$ clases, en el rango $-1 + \frac{1}{40}$ a $1 - \frac{1}{40}$ de v_a . Las elecciones de los rangos y valores de las grillas están basados en la experiencia de tratar con señales meteorológicas y sobre diversas pruebas que se realizaron sobre mediciones reales.

Las divisiones anteriores resultan en una grilla cuatri-dimensional de 187200 puntos, donde cada uno representa una situación meteorológica diferente. Para cada situación meteorológica se puede usar un gran número de realizaciones para entrenar la DNN. Sin embargo, en la práctica existen dos limitaciones para este número: la memoria RAM del ordenador donde se realiza el entrenamiento, y el tiempo que requiere entrenar la DNN, el cual se incrementa con la cantidad de datos de entrenamiento.

Teniendo en cuenta estas restricciones, para cada caso, excepto cuando $CSR \rightarrow -\infty$, se generan 5 realizaciones de series temporales de datos IQ, obteniendo de esta forma 5 DEPs para una misma situación meteorológica, cada una con $M = 50$ muestras. Para el caso $CSR \rightarrow -\infty$ se generan 25 realizaciones de series temporales de datos IQ. La elección del número de realizaciones para cada clase de CSR se basa en el hecho de que se quiere tener buen desempeño de la red cuando el clutter terrestre no está presente en la señal meteorológica. En escenarios reales, sólo una pequeña fracción de las celdas de rango están contaminadas con clutter terrestre, y esta contaminación disminuye a medida que se aumenta el ángulo de elevación de la antena. Dado el grillado anterior y el número de realizaciones, en total, el conjunto de datos de entrenamiento contiene 1080000 DEPs.

Debido a que no existe una rama para la SNR, para esa grilla en la generación de los datos de validación se decidió emplear una división de valores diferente a la empleada

Arquitecturas	Rama v_p			Rama σ_p			Rama CSR_p		
	1.º capa oculta	2.º capa oculta	3.º capa oculta	1.º capa oculta	2.º capa oculta	3.º capa oculta	1.º capa oculta	2.º capa oculta	3.º capa oculta
1	50	–	–	40	–	–	40	–	–
2	100	–	–	80	–	–	100	–	–
3	200	–	–	160	–	–	200	–	–
4	400	–	–	320	–	–	400	–	–
5	800	–	–	640	–	–	800	–	–
6	50	100	–	40	90	–	50	100	–
7	100	200	–	90	170	–	100	200	–
8	200	400	–	160	320	–	200	400	–
9	400	800	–	320	640	–	400	800	–
10	800	1600	–	640	1280	–	800	1600	–
11	50	70	100	40	60	90	50	70	100
12	100	150	200	90	110	130	100	150	200
13	200	250	300	150	200	250	200	250	300
14	300	350	400	250	350	400	300	350	400
15	1600	1800	2000	1600	1800	1900	1600	1600	1850

Tabla 5.1: Diferentes arquitecturas de redes neuronales totalmente conectadas.

en el entrenamiento. Se eligieron 10 valores uniformemente espaciados en el intervalo de 0 dB a 30 dB, mientras que las grillas CSR , v_p y σ_p permanecen igual que en la generación de los datos de entrenamiento. Con esta elección se busca tener un grillado de parámetros de los datos de validación que no coincida con los de entrenamiento, que permita realizar una mejor generalización. Para esta nueva división del parámetro SNR, se cuenta en total con 124800 configuraciones meteorológicas diferentes. En este caso, para cada situación meteorológica se generan 15 realizaciones de series temporales de datos IQ cuando $CSR \rightarrow -\infty$, y 3 realizaciones cuando $CSR \geq 0$, lo que implica un total de 432000 DEPs.

5.3. Estudio de arquitecturas

En esta sección se estudia el desempeño de diferentes arquitecturas de redes neuronales densas, es decir totalmente conectadas, de diferentes tamaños. El objetivo es encontrar entre las redes estudiadas, la que presente el mejor desempeño para los datos de validación. Se consideran redes neuronales (NN) con distinta cantidad de capas ocultas y diferentes número de neuronas por capa. La Tabla 5.1 muestra el número de neuronas para cada capa oculta de las 15 arquitecturas propuestas.

Las 15 arquitecturas se entrenan usando la librería tensorflow [87], versión 2.2.0 y el API Keras [88]. Todas las capas ocultas usan la función de activación ReLu, y las capas de salida la función de activación *softmax*, la cual proporciona las probabilidades de cada clase a la salida para cada rama. Como función de pérdida se usa *Categorical*

cross-entropy. Se adopta el optimizador Adam [64], basado en el descenso del gradiente, para el entrenamiento de los pesos de las neuronas. Se elige una tasa de aprendizaje y un tamaño de batch de 1×10^{-4} y 512, respectivamente. La elección de estos valores está basada en la experiencia en la resolución de este tipo de problemas. Además, se emplea la regularización *early stopping*, monitoreando la función de *loss* en la validación, tal que la misma no supere en 0,02 del mínimo valor obtenido durante el entrenamiento. A los fines de tener en cuenta el costo computacional, cabe destacar que el entrenamiento se realiza en una PC con Intel core i7 (3.4 GHz), 32 GB de memoria RAM y una tarjeta gráfica Nvidia 750 Ti con 2 GB de memoria RAM. Para todas las arquitecturas, se entrena usando la CPU y la GPU con el objetivo de comparar ambos tiempos de entrenamiento. Para realizar la comparación entre las 15 arquitecturas se usan las métricas: *accuracy*, tiempo de entrenamiento y tiempo de predicción.

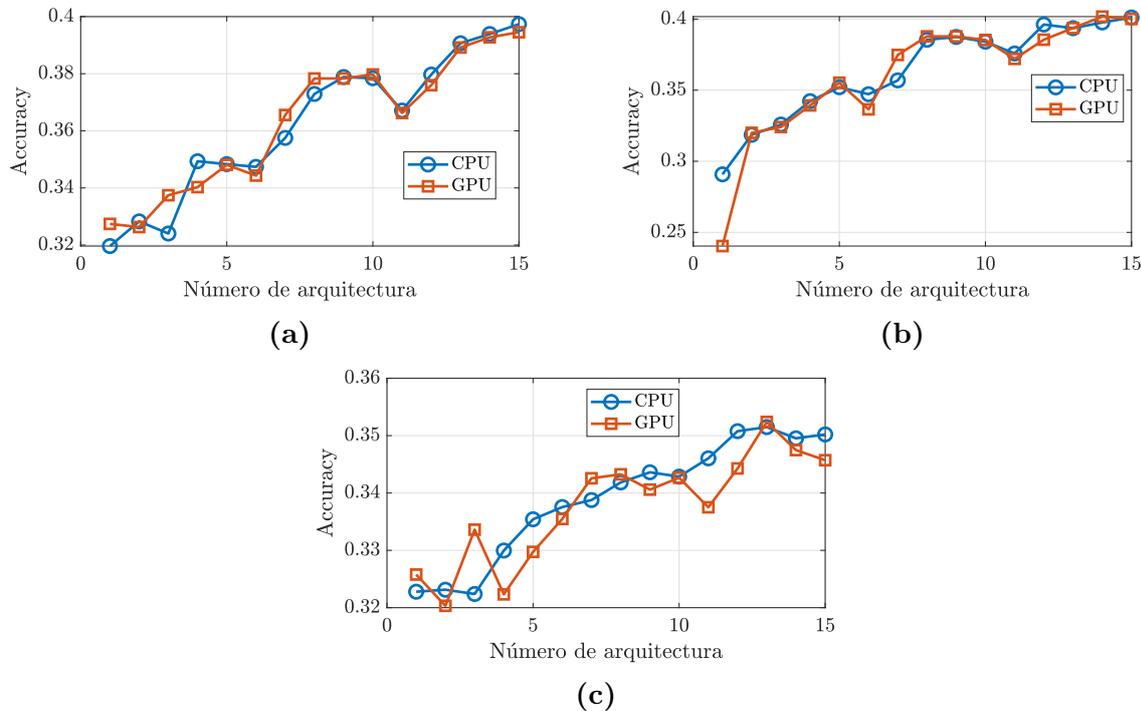


Figura 5.4: Accuracy usando los datos de validación para las 15 estructuras de NN. (a) Rama v_p . (b) Rama σ_p . (c) Rama CSR_p .

La Figura 5.4 muestra el accuracy para cada rama de las NNs, después del entrenamiento. La Figura 5.4(a) se corresponde a la rama v_p , la Figura 5.4(b) a la rama σ_p y la Figura 5.4(c) a la rama CSR_p . En las ramas de v_p y σ_p se aprecia que la arquitectura número 15 es la que presenta el mayor accuracy, lo que se corresponde al mejor desempeño, mientras que para la rama CSR_p , la arquitectura número 13 es la que arroja el mayor valor de accuracy. La diferencia numérica que se observa en el valor del accuracy para la CPU y la GPU radica en la inicialización de los pesos al comenzar el entrenamiento, y a la elección aleatoria de los batch.

Las Figuras 5.5(a) y 5.5(b) muestran los tiempos, en escala logarítmica, de entrenamiento por época y los tiempos promedios de predicción de las 15 arquitecturas, usando la CPU y la GPU, respectivamente. En general, para todas las arquitecturas se observa que los tiempos de entrenamiento con GPU son menores que los obtenidos con CPU. Por otro lado, para la predicción se realizaron 5 corridas por cada arquitectura y unidad de procesamiento; con el objetivo de calcular valores medios. Con respecto a los tiempos resultantes al emplear la CPU, cabe destacar que varían mucho con el tamaño de la red (número de parámetros a entrenar). En cuanto a los tiempos usando la GPU, para las arquitecturas analizadas desde el punto de vista práctico no dependen de la arquitectura, son aproximadamente constantes. En el procesamiento empleando GPU el proceso se divide en dos etapas: la primera, es la transferencia de datos de la CPU hacia la GPU, que depende del número de datos a transferir; y la segunda, es el procesamiento propiamente dicho, que involucra los cálculos (multiplicaciones de matrices, sumas, evaluación de funciones, etc) que realiza la NN. Esta última etapa es la que depende de la estructura de la red. Teniendo presente lo anterior, se puede inferir que para la GPU predomina el tiempo de transferencia de datos de la CPU hacia la GPU por sobre el tiempo de procesamiento, debido al comportamiento aproximadamente constante que se observa.

Si bien, el tiempo de predicción es menor para algunas arquitecturas usando la CPU, en general, cuando la NN presenta muchos parámetros, se recomienda usar la GPU. Por otro lado, es importante notar que para la GPU el tiempo de predicción de la arquitectura número 15 es aproximadamente el doble que el tiempo de las demás arquitecturas. En aplicaciones meteorológicas en tiempo real, se debe procesar un volumen de datos grande entre barridos, lo que implica un uso eficiente de los recursos para reducir el costo computacional, manteniendo un buen desempeño en las estimaciones. Por lo tanto, para lograr un balance entre costo computacional y desempeño de las estimaciones, basado en los resultados obtenidos, se propone usar la arquitectura número 13 para resolver el problema de filtrado de clutter y estimación de momentos.

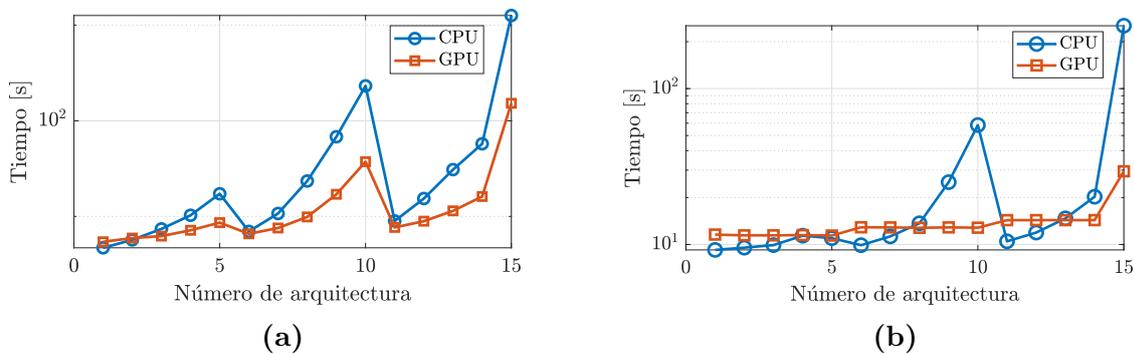


Figura 5.5: Tiempos de entrenamiento y predicción para varias estructuras de NN, usando GPU y CPU. (a) Entrenamiento. (b) Predicción.

5.3.1. Entrenamiento y validación de la arquitectura elegida

En esta sección se estudia en detalle el entrenamiento y la validación de la arquitectura número 13, a la cual se llamará DNN a lo largo de lo que resta del capítulo. Con el objetivo de mejorar el desempeño de la red, la misma se reentrena con un conjunto de datos mayor al utilizado en la Sección 5.3. Manteniendo el mismo grillado de parámetros introducido en la Sección 5.2.2, para los datos de entrenamiento, se triplica la cantidad de DEPs para cada configuración meteorológica, respecto a lo presentado en la Sección 5.2.2. Para los datos de validación se aumenta el número de realizaciones de 3 a 8 para las configuraciones meteorológicas donde existe clutter terrestre, y de 15 a 40 realizaciones para las situaciones en las que este último no está presente. Los hiperparámetros del entrenamiento son iguales a los presentados en la Sección 5.3.

La Figura 5.6 muestra el desempeño del entrenamiento y la validación en función del número de épocas. En la Figura 5.6(a) se observa la función de loss, mientras que en la Figura 5.6(b) se observa el accuracy. De ambas se aprecia que para el entrenamiento y la validación, las funciones de loss disminuyen y los accuracy aumentan con el número de épocas. Esto indica que la DNN aprende a predecir las clases de forma correcta.

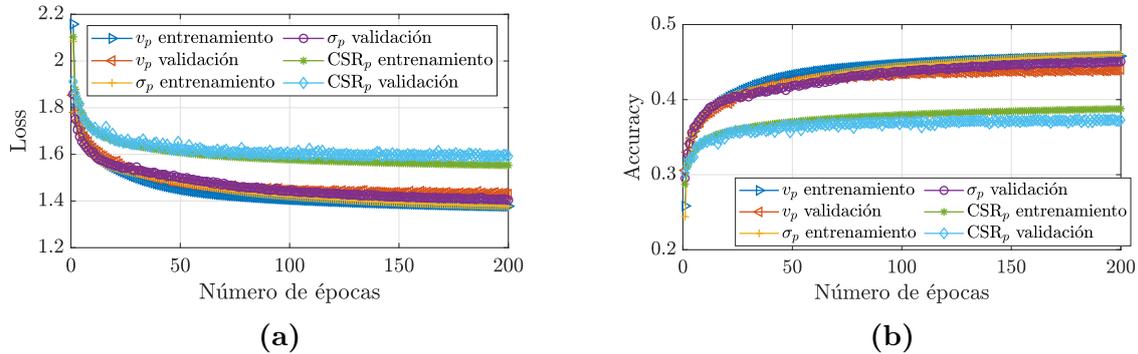


Figura 5.6: Desempeño del entrenamiento y la validación de la DNN. (a) Loss. (b) Accuracy.

De la Figura 5.6(b) se identifica que los accuracy de validación para las ramas v_p , σ_p y CSR_p son aproximadamente, 0.43, 0.44 y 0.36, respectivamente. Los valores de esta métrica son bajos con respecto a lo esperado para este tipo de herramientas. Sin embargo, es importante tener presente que, la causa es que el accuracy penaliza por igual, ya sea que se cometa un error de una clase con su vecina o bien entre varias clases alejadas. Para este problema esos tipos de errores no representan lo mismo, debido a que si bien opera como un problema de clasificación el objetivo es realizar una estimación. Teniendo en cuenta como se elige la salida de cada rama, en términos del error de estimación, este se mantendrá pequeño si el error en la clasificación es entre clases vecinas, mientras que aumentará cuando el error en la clasificación sea entre clases alejadas. Por lo tanto, la finalidad de la DNN es que sea capaz de elegir entre todas las clases, la correcta para cada rama, y en el peor de los casos, que la clase elegida

sea lo más cercana posible a la clase verdadera. Con el motivo de profundizar sobre la validación de la DNN entrenada, se propone como métrica calcular la diferencia entre los índices de las clases que predice la DNN y las verdaderas.

Las Figuras 5.7(a), 5.7(b) y 5.7(c) muestran los histogramas de los errores de clases para las ramas v_p , σ_p y CSR_p , respectivamente. Es importante mencionar que con la elección de la grilla cuadri-dimensional realizada en la Sección 5.2.2, la distancia entre dos clases consecutivas para las ramas v_p , σ_p y CSR_p , se corresponde a $0,05v_a$, $0,03v_a$ y $2,08$ dB, respectivamente. La Figura 5.7(a) permite concluir que más del 80 % de las predicciones se encuentran a lo sumo a una clase de diferencia. La distribución de los errores de clases tiene aproximadamente forma gaussiana, centrada en cero. Esto sugiere que la estimación de velocidad resulta insesgada. Los errores que se observan a aproximadamente 40 clases de diferencias, se corresponden a la situación en las que v_p se encuentra cerca de los valores $\pm v_a$. No obstante, la probabilidad de ocurrencia que muestran los resultados, a los fines prácticos, es baja. De la Figura 5.7(b) se observa que más del 75 % de las predicciones se encuentran a lo sumo a una clase de diferencia, y que la distribución de los errores de clases también posee forma gaussiana, centrada en cero. En relación a la rama de CSR_p , la Figura 5.7(c) muestra que más del 60 % de las clases que selecciona la DNN, se encuentran a lo sumo, a una clase de diferencia respecto de la clase verdadera. Al igual que en los casos anteriores, la distribución de errores de clases para esta rama tiene forma gaussiana centrada en cero.

El último análisis muestra que si bien la DNN entrenada no alcanza los valores de accuracy esperados, en caso de equivocarse, el error de la diferencia de clases es bajo, arrojando, en general, errores pequeños en la estimación de los parámetros. Los errores resultantes poseen densidades de probabilidad (aproximadas por los histogramas) centradas en cero, lo que indica que no poseen sesgo, y, además, tienen forma de campana angosta, lo que muestra que la dispersión es pequeña. Por otra parte, las situaciones en las que las clases predichas se encuentran alejadas de las verdaderas, se corresponden a DEPs, en las cuales es difícil identificar las diferentes contribuciones a la señal meteorológica; como son los casos: bajos valores de SNR, altos valores σ_p , y altos y bajos valores de CSR, lo cual es esperable, debido a que estos son los casos en los que los algoritmos de estimación incrementan sus errores.

5.4. Experiencias con datos sintéticos

En esta sección se estudia el desempeño de la DNN por medio de simulaciones numéricas a partir de diferentes experimentos. Se consideran dos escenarios: el primero, cuando el clutter no está presente en la señal meteorológica; y el segundo, cuando el clutter contamina la señal. También se estudia el desempeño de otros algoritmos, y se comparan con el de la DNN. Para el primer escenario, se compara con el desempeño del

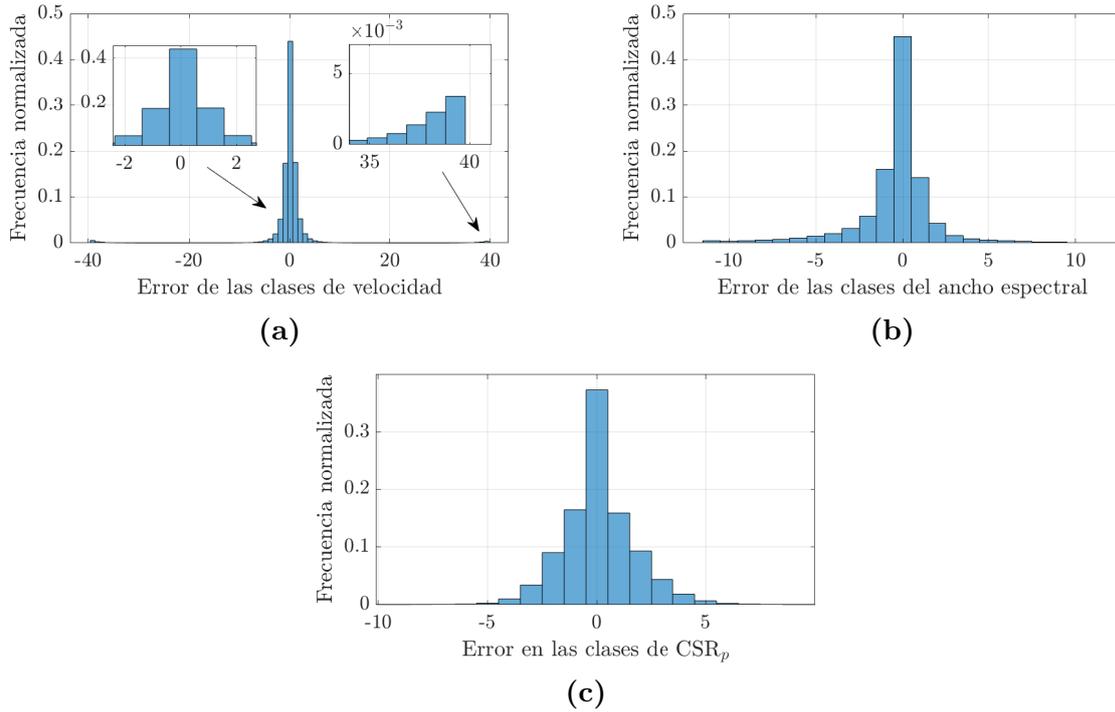


Figura 5.7: Histogramas de los errores de clases. (a) Rama v_p . (b) Rama σ_p . (c) Rama CSR_p .

algoritmo PPP, descrito en la Sección 2.4.1, y para el segundo escenario se compara con el desempeño de GMAP, descrito en la Sección 2.4.3.

Los experimentos consisten en variar de a dos parámetros en simultáneo, evaluando en cada caso los estimados de los momentos espectrales. Los conjuntos de dos parámetros se toman entre la CSR, la SNR, la velocidad Doppler media y el ancho espectral. El sesgo y la desviación estándar (std) se toman como métricas de desempeño.

Los datos meteorológicos se generan usando un esquema similar al presentado en la Sección 5.2.2, pero considerando un grillado diferente para los parámetros. Dada una DEP de entrada, la DNN selecciona la clase a la salida con mayor probabilidad en cada una de las ramas. Los parámetros generales de las simulaciones se presentan en la Tabla 5.2. En los experimentos en los que se varía la velocidad Doppler media, la misma se genera de forma aleatoria. Se hace corresponder un valor aleatorio por cada clase de velocidad, cubriendo de esta forma todo el rango Doppler. Al elegir un valor distinto al centro de la clase, hace que exista sesgo en la estimación. Por ejemplo: si el valor elegido de forma aleatoria es $v_p = 0,3$ m/s, y el centro de la clase más cercana es $v_p^0 = 0$ m/s, entonces el sesgo de la estimación, en caso de que la red elija correctamente la clase de velocidad es $v_p - v_p^0 = 0,3$ m/s. Este razonamiento se aplica para las estimaciones de σ_p y CSR_p .

Parámetro	Símbolo	Valor
Frecuencia de portadora	F_c [GHz]	5,6
Longitud de onda	λ [cm]	5,35
Velocidad Doppler media	v_p [m/s]	0
Nro. de muestras (pulsos)	M	50
PRI	T_u [ms]	0,5
Velocidad máxima no ambigua	v_a [m/s]	26,8

Tabla 5.2: Parámetros para la simulación.

5.4.1. Desempeño de la DNN en ausencia de clutter terrestre

La DNN fue diseñada con la capacidad de estimar la velocidad Doppler media y el ancho espectral en ausencia de clutter terrestre como consecuencia de que es una situación muy frecuente en las aplicaciones prácticas. Por ese motivo, en esta sección se evalúa el desempeño de la DNN en el primer escenario propuesto, es decir cuando el clutter no contamina la señal meteorológica. Para llevar a cabo el experimento, se fija $v_p = 0$ m/s y se varían los parámetros SNR de 0 dB a 30 dB y σ_p de 1,07 m/s a 10,7 m/s. Además de la DNN, con el objetivo de comparar su desempeño, se usa el algoritmo PPP para la estimación de velocidad y ancho espectral. Para cada valor de σ_p y SNR , se generan 1000 realizaciones diferentes. Los parámetros generales de la simulación se encuentran en la Tabla 5.2.

En la Figura 5.8 se presentan los resultados del análisis de error de la estimación de velocidad Doppler media. Las Figuras 5.8(a) y 5.8(b) muestran el sesgo obtenido usando la DNN y PPP, respectivamente; mientras que las Figuras 5.8(c) y 5.8(d) muestran la desviación estándar obtenida usando la DNN y PPP, respectivamente. De las Figuras 5.8(a) y 5.8(b) se observa que ambos algoritmos son insesgados desde el punto de vista práctico para $SNR \geq 5$ dB, y que, para $SNR \leq 5$ dB el sesgo aumenta. En el caso de la desviación estándar, se observa que la DNN presenta gran dispersión para $SNR \leq 10$ dB y σ_p cercana a los valores límites: inferior $\sigma_p = 0,04v_a = 1,07$ m/s y superior $\sigma_p = 0,4v_a = 10,7$ m/s.

Este comportamiento para bajos valores de σ_p se debe a que la red se confunde, considerando que el espectro del fenómeno meteorológico corresponde a clutter terrestre, como consecuencia de que $v_p = 0$ m/s y el ancho espectral es angosto, y selecciona como espectro del fenómeno parte del ruido. Por otro lado, para valores de σ_p en el extremo superior, como consecuencia de que el ancho espectral es muy grande, la red confunde el espectro del fenómeno meteorológico con ruido. Esta tendencia va desapareciendo a medida que aumenta la SNR , debido a que los espectros que corresponden al fenómeno meteorológico y al ruido se vuelven más identificables. De la Figura 5.8(d)

se aprecia que PPP presenta un buen comportamiento para el intervalo de valores estudiado, exceptuando $SNR \leq 5$ dB y $\sigma_p \geq 7$ m/s.

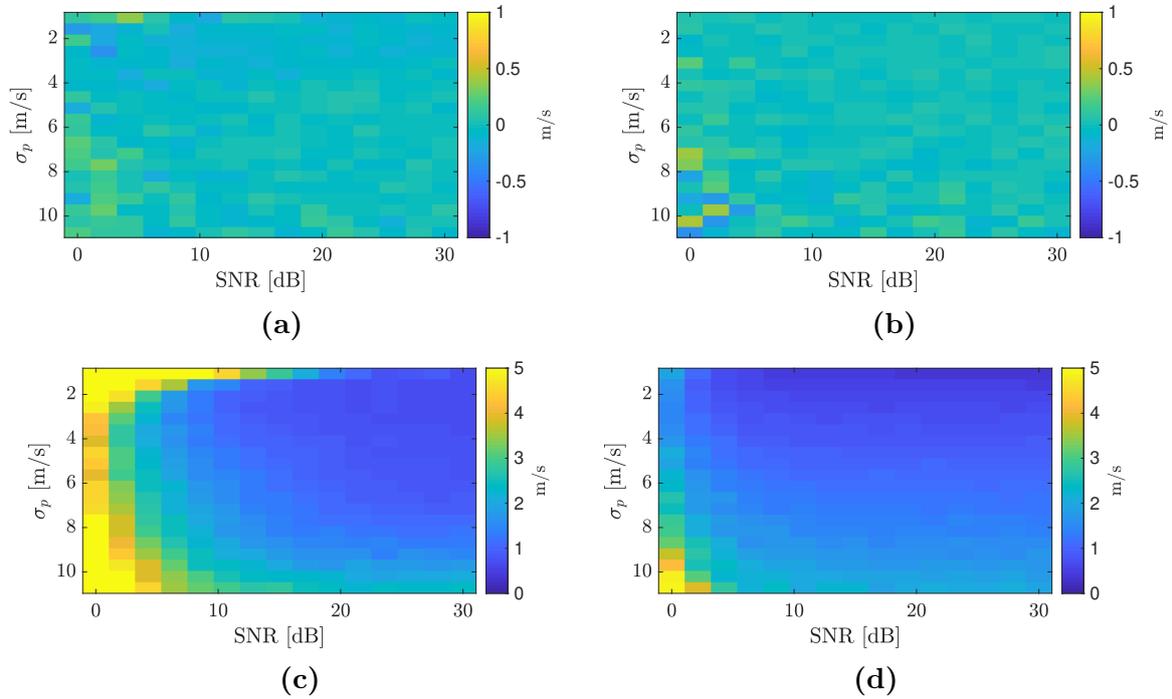


Figura 5.8: Análisis de error en la estimación de velocidad Doppler media del fenómeno en ausencia de clutter terrestre. (a) Sesgo DNN . (b) Sesgo PPP. (c) Desviación estándar DNN . (d) Desviación estándar PPP .

En la Figura 5.9 se presentan los resultados del análisis de error del ancho espectral. Las Figuras 5.9(a) y 5.9(b) muestran el sesgo obtenido utilizando la DNN y PPP, respectivamente; mientras que las Figuras 5.9(c) y 5.9(d) muestran la desviación estándar obtenida utilizando la DNN y PPP, respectivamente. De la Figura 5.9(a) se observa que la DNN es insesgada para $SNR \geq 10$ dB, y que para valores de σ_p chicos y $SNR \leq 10$ dB comienza a crecer el sesgo. Este comportamiento tiene su causa en el efecto descrito para el caso anterior, en el que la red se confunde el espectro del fenómeno con clutter terrestre, cuando este último no se encuentra presente, y asigna al fenómeno parte del espectro del ruido arrojando valores de anchos espectrales mayores a los esperados y con una dispersión significativa. De la Figura 5.9(b) se aprecia que PPP es insesgado para $SNR \geq 10$ dB y $\sigma_p \leq 8$ m/s. Para $\sigma_p \geq 8$ m/s, resulta sesgada la estimación, lo que se condice con los desarrollos teóricos [3]. Por otro lado, en esta situación aumenta el piso de la DEP, lo cual hace que se subestime la potencia del fenómeno, lo que conlleva a un deterioro en la estimación del ancho espectral.

En las Figuras 5.9(c) y 5.9(d) se aprecia que ambos algoritmos presentan bajos valores de std para $SNR \geq 10$ dB y $\sigma_p \leq 8$ m/s. Sin embargo, en el caso de la DNN, la observación anterior no se cumple para σ_p pequeños, cercanos al límite inferior $\sigma_p = 0,04v_a$. En general, tanto para la estimación de velocidad, como para la estimación

del ancho espectral, se advierte que existe una región de valores común ($SNR \geq 10$ dB y $\sigma_p \leq 8$ m/s, aproximadamente), donde ambos algoritmos presentan buen desempeño. También se observa que el desempeño se degrada a medida que disminuye SNR , siendo esta degradación más significativa para la DNN.

A pesar de que PPP presenta un desempeño ligeramente mejor que la DNN, en general, los resultados de ambos algoritmos son comparables. Se debe tener en cuenta que para la DNN se eligió la situación más desfavorable, es decir con $v_p = 0$. En el caso de PPP esto no es un problema porque está diseñado para operar con señales compuestas sólo de contribuciones de un fenómeno meteorológico más ruido, mientras que como se verá en la próxima sección la DNN opera tanto en ausencia como en presencia de clutter terrestre. Cuando existen contribuciones de clutter en la señal, las estimaciones de PPP se vuelven muy sesgadas. La capacidad de la DNN de contemplar ambas situaciones penaliza aquellas en las no existe clutter terrestre. Si se quiere una DNN con mejor desempeño en ausencia de clutter terrestre, se recomienda entrenar la red contemplando únicamente DEPs en esta condición.

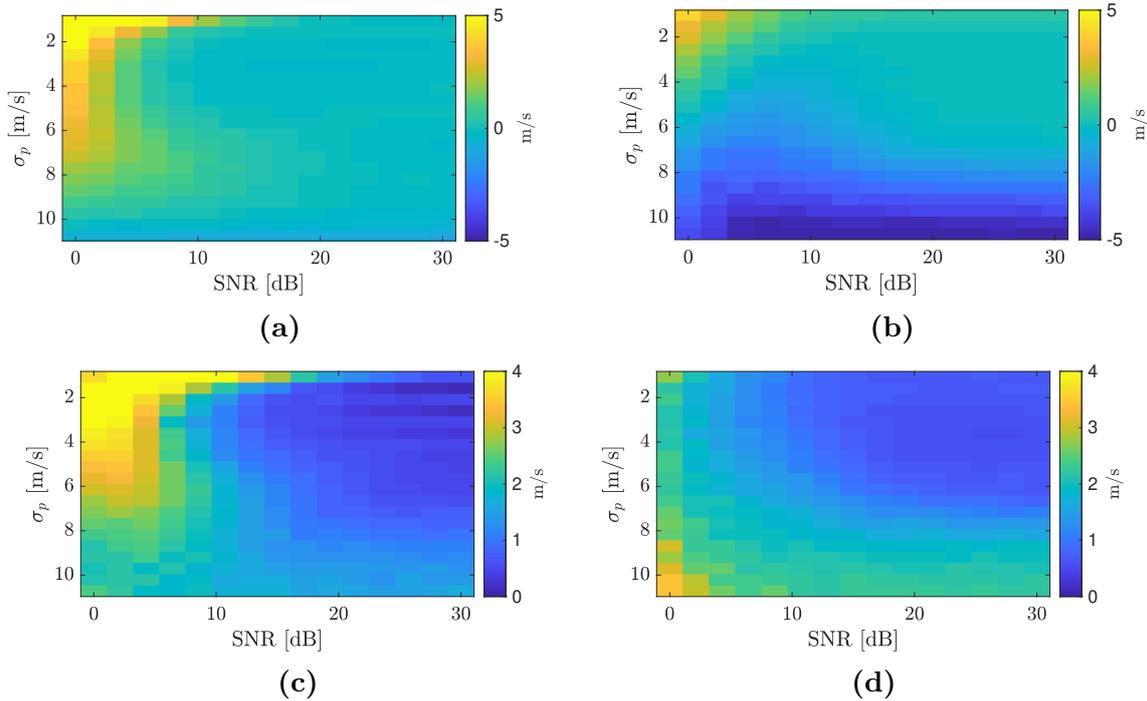


Figura 5.9: Análisis de error en la estimación del ancho espectral del fenómeno en ausencia de clutter terrestre. (a) Sesgo DNN . (b) Sesgo PPP. (c) Std DNN . (d) Std PPP.

5.4.2. Desempeño de la DNN en presencia de clutter terrestre

En esta sección se estudia el desempeño de la DNN en el segundo escenario propuesto, es decir cuando existe clutter terrestre contaminando la señal meteorológica. Dado que el problema a analizar posee cuatro dimensiones, se presentan tres experimentos:

en el primero, se fijan los valores de SNR y CSR , y se analizan tres valores de σ_p ; en el segundo, se fijan los valores de σ_p y SNR , y se analizan tres valores de CSR ; mientras que, en el tercero, se fijan los valores de σ_p y CSR , y se analizan tres valores de SNR . En los tres experimentos, se varía la velocidad v_p desde $-v_a$ hasta v_a como se explicó al inicio de la presente sección. Además de la DNN, se utiliza el algoritmo GMAP, con el objetivo de comparar ambos desempeños. En los tres experimentos, para cada configuración meteorológica se contemplan 1000 realizaciones de datos IQ. Los parámetros generales de las simulaciones se encuentran en la Tabla 5.2, considerando $\sigma_t = 0,28$ m/s.

Diferentes anchos del espectro

En el primer experimento se examinan diferentes valores de σ_p : 3, 4 y 5 m/s; fijando $CSR = 40$ dB, $SNR = 20$ dB y $p_p = 1$ u.a./m/s (unidades arbitrarias sobre metros por segundos). Antes de realizar el análisis de error en la estimación de la potencia del fenómeno, se estudian las estimaciones de la potencia de clutter P_c y de CSR_p . En las Figuras 5.10(a) y 5.10(b) se observan las estimaciones de CSR_p y su desviación estándar, respectivamente. De la Figura 5.10(a) se aprecia que existe sesgo en la estimación alrededor de la velocidad Doppler cero. Cuando el espectro del fenómeno se superpone al del clutter, es más difícil distinguir la contribución de cada uno sobre la DEP total, haciendo que la red se confunda entre clases alejadas con mayor frecuencia. Además, este sesgo aumenta a menor valor de σ_p , dado que es mayor la superposición. De la Figura 5.10(b) se observa que la std sigue el comportamiento del sesgo, degradándose el desempeño a medida que la velocidad del fenómeno se acerca al origen. Las Figuras 5.10(c) y 5.10(d) muestran el sesgo y la desviación estándar de la potencia de clutter estimada, respectivamente. De la Figura 5.10(c) se aprecia que las estimaciones son insesgadas desde el punto de vista práctico, y que, como es de esperar, no dependen de σ_p . De la Figura 5.10(d) se destaca que la std tampoco depende de σ_p , y que su valor promedio es aproximadamente el 95 % del valor nominal fijado para la simulación: $P_c = 10000$ u.a.

Las Figuras 5.11(a) y 5.11(b) muestran el sesgo y la desviación estándar de la estimación de potencia del fenómeno, respectivamente. Se observa que ambos algoritmos presentan sesgo alrededor de la velocidad Doppler media cero. En el caso de la DNN este resultado se explica a partir de la propagación de errores de la estimación de \widehat{CSR}_p , teniendo en cuenta que, como se mencionó en la Sección 5.2, la estimación de la potencia del fenómeno depende de los estimados \hat{P}_c y \widehat{CSR}_p . Siendo la dependencia con este último parámetro de forma exponencial. Por otro lado, para GMAP el sesgo es menor para mayor valor de σ_p . Este resultado es esperado, debido a que mientras más ancho es el espectro del fenómeno, menor es el número de sus componentes espectrales remo-

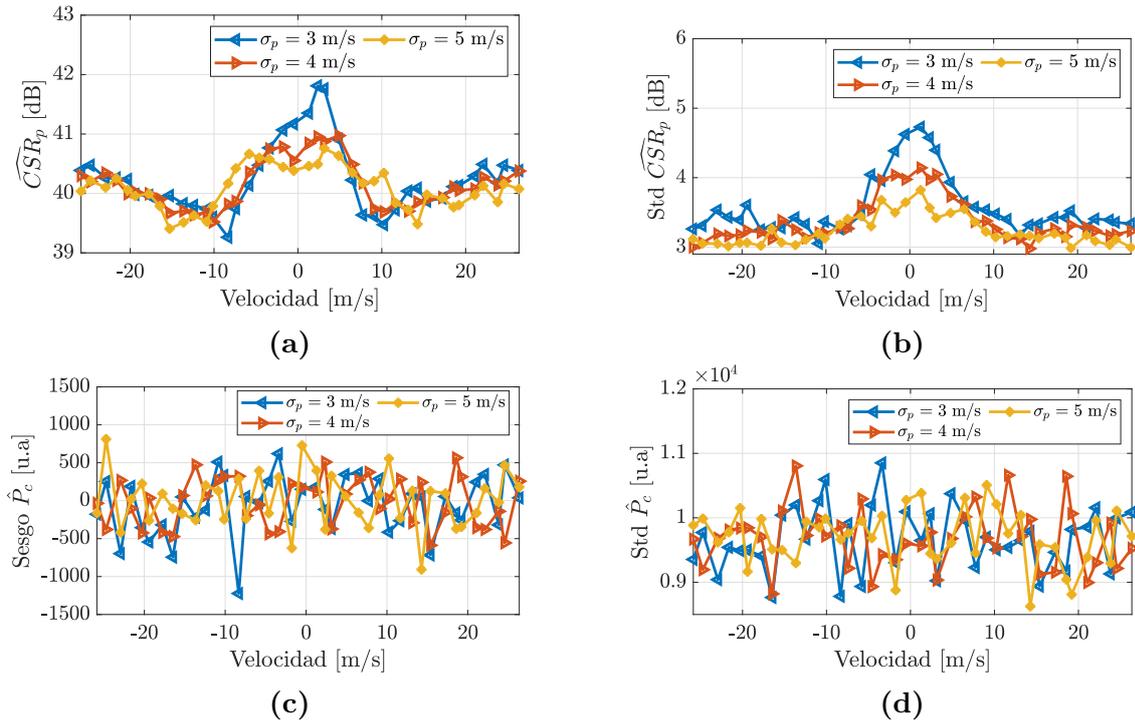


Figura 5.10: Análisis de error en la estimación de \widehat{CSR}_p y en la potencia del clutter para diferentes σ_p . (a) Estimación de \widehat{CSR}_p . (b) Desviación estándar \widehat{CSR}_p . (c) Sesgo potencia de clutter. (d) Desviación estándar potencia de clutter.

vidas en el filtrado; permitiendo tener una buena primera estimación de su potencia. A medida que v_p se aleja del origen, en GMAP se observa que no existe sesgo desde el punto de vista práctico, lo cual indica la correcta eliminación del clutter.

De la Figura 5.11(b) se aprecia que GMAP presenta menores valores de std en todo el intervalo Doppler. La explicación del peor desempeño de la DNN radica en la forma en que se estima la potencia del fenómeno, principalmente en su dependencia exponencial con CSR_p , la cual es la mayor fuente de dispersión. Además, sumado a esto último la estimación de la potencia de clutter afecta el resultado final de std \hat{p}_p .

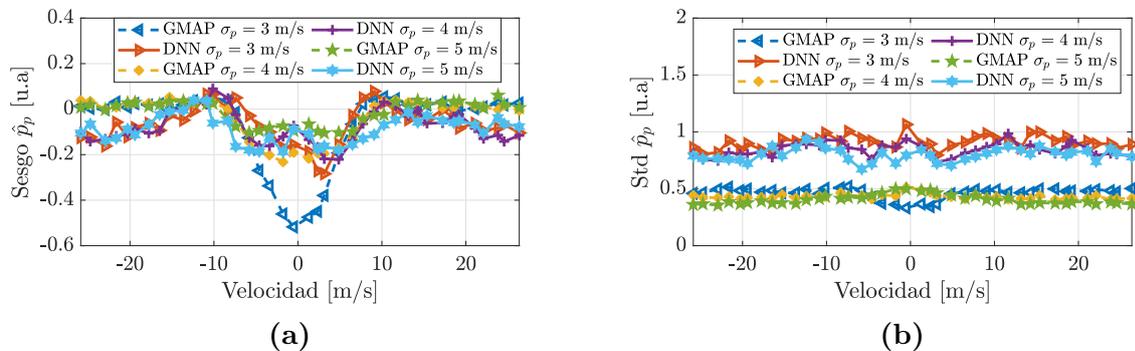


Figura 5.11: Análisis de error en la estimación de la potencia del fenómeno en presencia de clutter terrestre para diferentes σ_p . (a) Sesgo. (b) Desviación estándar.

En la Figura 5.12 se observa el análisis de error en la estimación de la velocidad

Doppler media, usando la DNN y GMAP. En la Figura 5.12(a) se aprecia que en general la DNN presenta un menor sesgo que GMAP en todo el intervalo Doppler, y sus estimaciones se pueden considerar insesgadas desde el punto de vista práctico.

Asimismo, en GMAP se observa sesgo en las velocidades cercanas a ± 5 m/s. En esa región de velocidades existe una superposición parcial entre las DEP del fenómeno y del clutter, que llevan a que una vez filtrado este último el espectro resultante pierda simetría, lo que implica una estimación inicial de velocidad muy errónea. La Figura 5.12(b) muestra la desviación estándar. De la misma, se aprecia que, en general, la DNN presenta menores valores de dispersión que GMAP en todo el intervalo Doppler. En el caso de GMAP, debido a que se usa PPP para la estimación de los momentos, la std aumenta con el valor de σ_p , como predice la teoría [3].

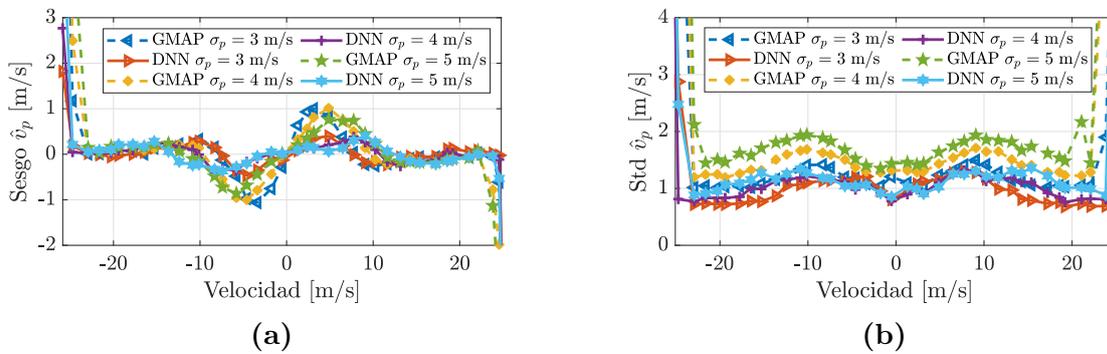


Figura 5.12: Análisis de error en la estimación de la velocidad Doppler media del fenómeno en presencia de clutter terrestre para diferentes σ_p . (a) Sesgo. (b) Desviación estándar.

La Figura 5.13 muestra el análisis de error en la estimación del ancho espectral usando el algoritmo GMAP y la DNN. En la figura 5.13(a) se observa el sesgo, y se advierte que GMAP presenta estimaciones sesgadas, principalmente, alrededor de la velocidad 0 m/s. Debido a que PPP usa el estimado de la potencia del fenómeno para calcular el ancho espectral, y a partir de los resultados presentados en la Figura 5.11(a), se concluye que, dada la superposición de los espectros del clutter y del fenómeno, después del filtrado, se subestima la potencia de este último, sesgando la estimación de σ_p . Este sesgo disminuye a medida que se incrementa σ_p . Por otro lado, se aprecia que la DNN arroja estimaciones insesgadas para todo el intervalo Doppler. La Figura 5.13(b) muestra la std. De la misma, se observa que la DNN presenta menores valores que GMAP en todo el rango Doppler.

En general, excepto para la estimación de potencia, la DNN presenta mejor desempeño que GMAP para las condiciones meteorológicas simuladas.

Diferentes CSR

En el segundo experimento se examinan diferentes valores de CSR: 30 dB, 40 dB y 45 dB; fijando $SNR = 20$ dB, $\sigma_p = 4$ m/s y $p_p = 1$ u.a/m/s. La Figura 5.14

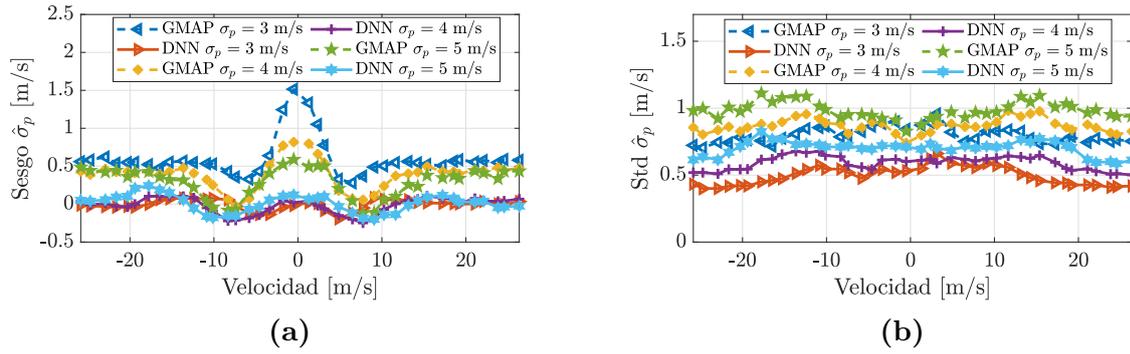


Figura 5.13: Análisis de error en la estimación del ancho espectral del fenómeno en presencia de clutter terrestre para diferentes σ_p . (a) Sesgo. (b) Desviación estándar.

muestra los errores en la estimación de potencia del fenómeno usando GMAP y la DNN. En la Figura 5.14(a) se observa el sesgo. Para ambos algoritmos se aprecia sesgo alrededor de la velocidad $v_p = 0$ m/s, el cual está relacionado con la superposición en el espectro entre el fenómeno y el clutter, como se explicó en el experimento anterior. Para GMAP el sesgo disminuye en los extremos del rango Doppler, confirmando la correcta eliminación del clutter. Por su parte, para la DNN se observa sesgo en todo el intervalo Doppler, y se destaca, que para la situación en la que $CSR = 30$ dB el sesgo es el menor entre los tres casos estudiados. En la Figura 5.14(b) se muestra la std. De la misma, se advierte que GMAP presenta menores valores que la DNN en todo el intervalo Doppler. La explicación de los valores de std para la DNN se debe a la naturaleza de la estimación de p_p , al igual que se mencionó en el primer experimento.

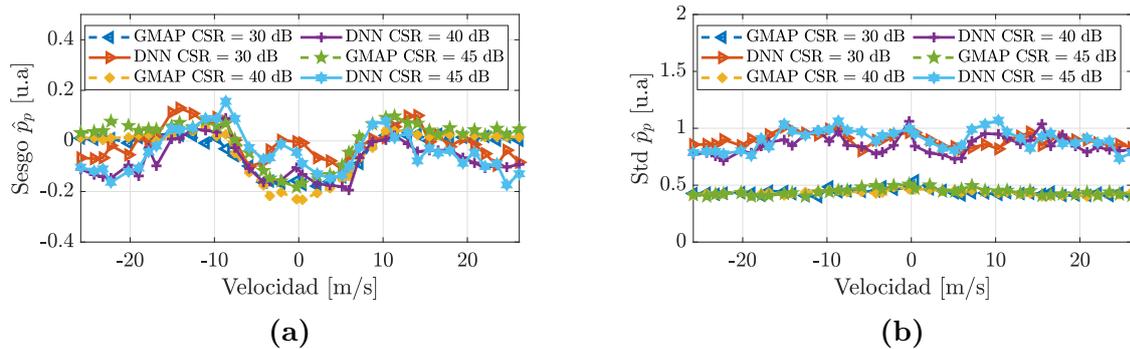


Figura 5.14: Análisis de error en la estimación de la potencia del fenómeno en presencia de clutter terrestre para diferentes valores de CSR . (a) Sesgo. (b) Desviación estándar.

La Figura 5.15 muestra el análisis de error en la estimación de velocidad Doppler media usando GMAP y la DNN. En la Figura 5.15(a) se observa el sesgo. Para la DNN se aprecia que las estimaciones se pueden considerar insesgadas desde el punto de vista práctico en todo el intervalo Doppler, aunque existen algunas regiones de velocidades, ± 8 m/s, en las cuales existe un pequeño sesgo para los tres valores de CSR estudiados. Por su parte, para GMAP se observa sesgo apreciable alrededor de las velocidades ± 5 m/s cuando CSR toma los valores 30 dB y 40 dB. Este sesgo se debe a la superposición

parcial entre el espectro del clutter y el espectro del fenómeno, como se explicó en el primer experimento. En el caso particular de $CSR = 45$ dB, se aprecia que GMAP presenta sesgo en las velocidades $v_p = \pm 12$ m/s. Este sesgo se debe al leakage, ya que, la ventana Blackman no atenúa del todo los lóbulos secundarios del clutter. En la Figura 5.15(b) se observa la std. En general, la DNN presenta menores valores en todo el intervalo Doppler. Además, se aprecia que la std aumenta con el valor de CSR .

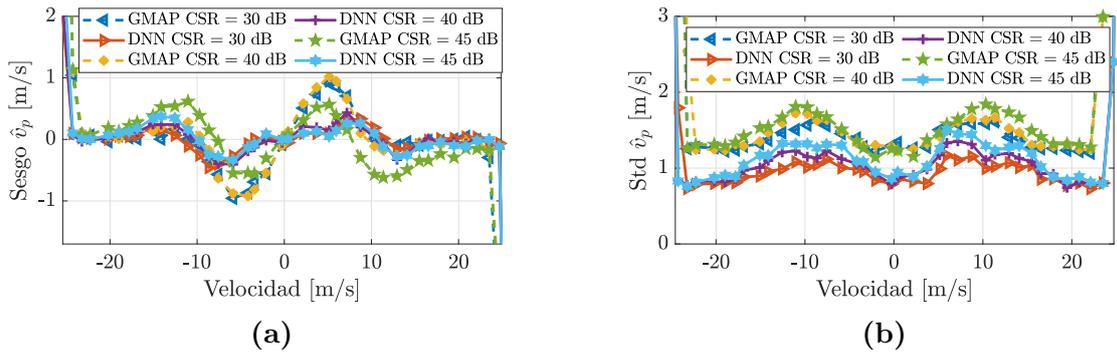


Figura 5.15: Análisis de error en la estimación de la velocidad Doppler media del fenómeno en presencia de clutter terrestre para diferentes valores de CSR . (a) Sesgo. (b) Desviación estándar.

En la Figura 5.16 se muestra el análisis de error en la estimación del ancho espectral del fenómeno usando GMAP y la DNN. En la Figura 5.16(a) se observa el sesgo. De la misma, se observa que en general la DNN es insesgada desde el punto de vista práctico, excepto alrededor de las velocidades $v_p = \pm 7$ m/s. Para GMAP existe sesgo apreciable alrededor de $v_p = 0$ m/s, y a medida que aumenta el valor de CSR , aumenta el sesgo en todo el intervalo Doppler. Esto último se debe al leakage. En la Figura 5.16(b) se muestra la desviación estándar de los estimados. Se observa que la DNN presenta menores valores que GMAP en todo el intervalo Doppler. Además, se advierte que estos valores para la DNN aumentan con el aumento de CSR .

En general, excepto para la estimación de potencia, la DNN presenta un mejor desempeño que GMAP para los diferentes valores de CSR estudiados.

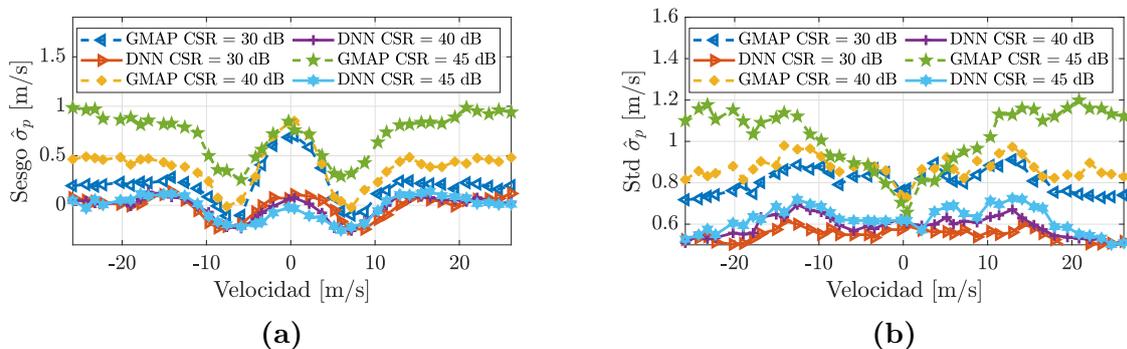


Figura 5.16: Análisis de error en la estimación del ancho espectral del fenómeno en presencia de clutter terrestre para diferentes valores de CSR . (a) Sesgo. (b) Desviación estándar.

5.4.3. Diferentes SNR

En el tercer experimento, se estudian tres valores de SNR : 10 dB, 15 dB y 20 dB; fijando $CSR = 40$ dB, $\sigma_p = 4$ m/s y $p_p = 1$ u.a./m/s. En las figuras que se muestran a continuación, varios de los resultados observados se explican usando los razonamientos mencionados en los experimentos anteriores. Por esta razón, el análisis presente se centra en los cambios en función de SNR . La Figura 5.17 muestra el análisis de error en la estimación de potencia del fenómeno usando GMAP y la DNN. En la Figura 5.17(a) se observa que para $SNR = 10$ dB, en GMAP existe sesgo para $|v_p| \geq 8$ m/s, sin embargo, el mismo disminuye para $|v_p| \leq 8$ m/s respecto a los otros valores de SNR . Este comportamiento para $SNR = 10$ dB se debe a que para valores de velocidad alejados del origen se sobre-estima la potencia del fenómeno, y cuando v_p es cercana a 0 m/s, debido al filtrado de clutter, la misma se subestima, explicándose de esta forma el cruce de valores positivos a negativos en el sesgo. Por otro lado, se advierte que la DNN mantiene un comportamiento similar en la estimación de la potencia para los diferentes valores de SNR analizados. La Figura 5.17(b) muestra la std. Se aprecia que GMAP presenta menores valores en todo el intervalo Doppler. Para la DNN se observa degradación alrededor del origen para la situación $SNR = 10$ dB. Este resultado es esperado, ya que, al disminuir la SNR , para $v_p = 0$ m/s existe mayor probabilidad de que la red no identifique correctamente las contribuciones de los tres espectros involucrados y reporte estimaciones con errores.

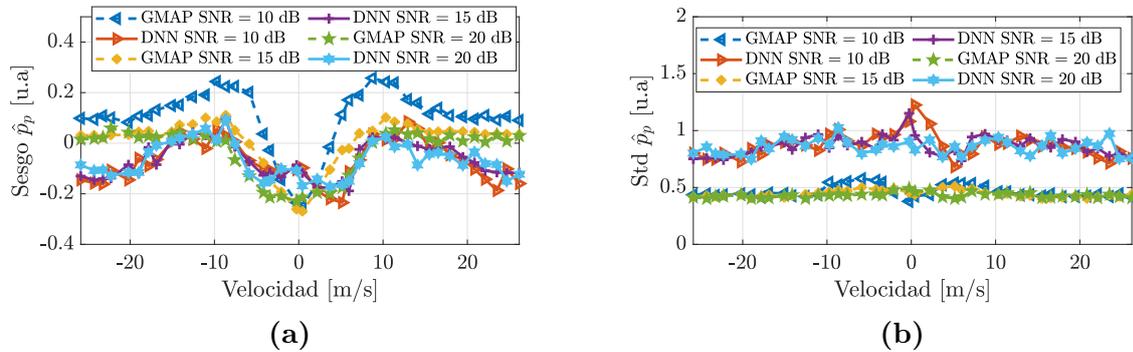


Figura 5.17: Análisis de error en la estimación de la potencia del fenómeno en presencia de clutter terrestre para diferentes valores de SNR . (a) Sesgo. (b) Desviación estándar.

Las Figuras 5.18(a) y 5.18(b) muestran el sesgo y la desviación estándar en la estimación de velocidad Doppler media del fenómeno, respectivamente. De la primera, se observa que las estimaciones empleando la DNN se pueden considerar insesgadas a los fines prácticos en el intervalo Doppler, excepto para las velocidades ± 5 m/s y $SNR = 10$ dB, donde se observa un pequeño sesgo. Por su parte, GMAP muestra un comportamiento similar al visto en los experimentos anteriores para $SNR = 15$ dB y $SNR = 20$ dB, pero para el caso de $SNR = 10$ dB, el sesgo es mayor y se encuentra alrededor de las velocidades $v_p = \pm 10$ m/s. Por otro lado, de la Figura 5.18(b) se

aprecia que para ambos algoritmos los valores de std disminuyen con el aumento de SNR , lo cual es un comportamiento esperado. En las situaciones $SNR = 15$ dB y $SNR = 20$ dB se aprecia que la DNN presenta mejor desempeño que GMAP en todo el intervalo Doppler. Para $SNR = 10$ dB el comportamiento anterior no se puede generalizar, existiendo zonas en las que GMAP presenta menores valores de desviación estándar, principalmente para velocidades cercanas al origen.

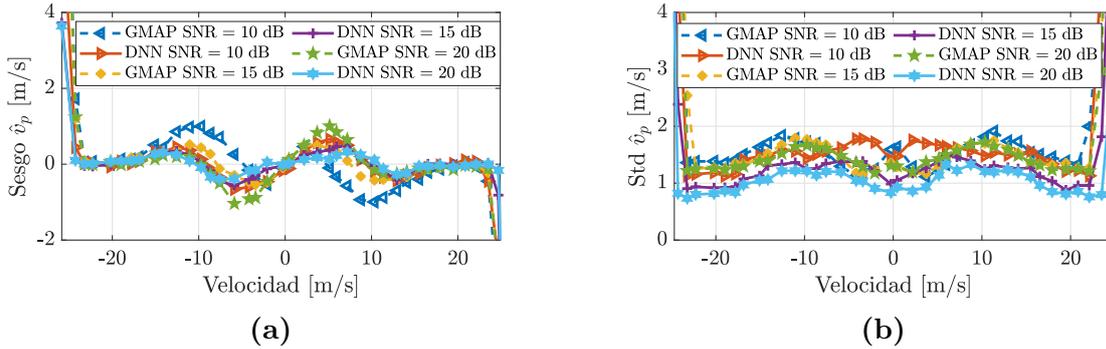


Figura 5.18: Análisis de error de la velocidad Doppler media del fenómeno en presencia de clutter terrestre para diferentes valores de SNR . (a) Sesgo. (b) Std.

Las Figuras 5.19(a) y 5.19(b) muestran el sesgo y la desviación estándar en la estimación del ancho espectral, respectivamente. Para $SNR = 10$ dB GMAP presenta un valor de sesgo considerable, y que, para esa situación, la DNN se puede considerar insesgada desde el punto de vista práctico. Sin embargo, para ese valor de SNR , la desviación estándar de la DNN es mayor que la de GMAP. Para GMAP, el sesgo disminuye a medida que aumenta la SNR . Para la DNN, el sesgo presenta un comportamiento similar para los valores de SNR estudiados. De la Figura 5.19(b) se observa que la std disminuye con el aumento de SNR para ambos algoritmos.

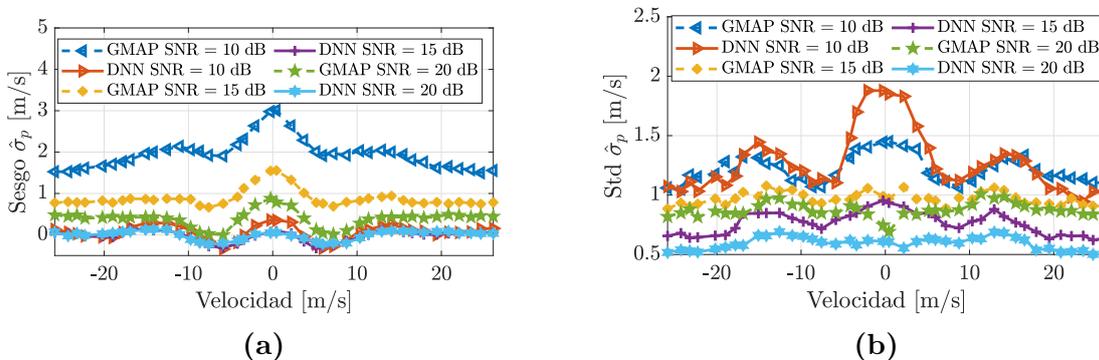


Figura 5.19: Análisis de error en la estimación del ancho espectral del fenómeno en presencia de clutter terrestre para diferentes valores de SNR . (a) Sesgo. (b) Desviación estándar.

En resumen, de los tres experimentos, se concluye que, en general, la DNN presenta mejor desempeño que GMAP en la estimación de v_p y σ_p , para el rango de valores de

los parámetros estudiados. Lo contrario ocurre en la estimación de p_p , en la cual la DNN presenta peor desempeño que GMAP.

5.5. Procesamiento de datos reales

En esta sección se emplea la DNN entrenada con datos sintéticos para estimar los momentos espectrales de mediciones adquiridas con el radar meteorológico RMA-12. La PRI del barrido considerado es 0.5 ms, lo que equivale a una velocidad máxima no ambigua de $v_a = 26,66$ m/s.

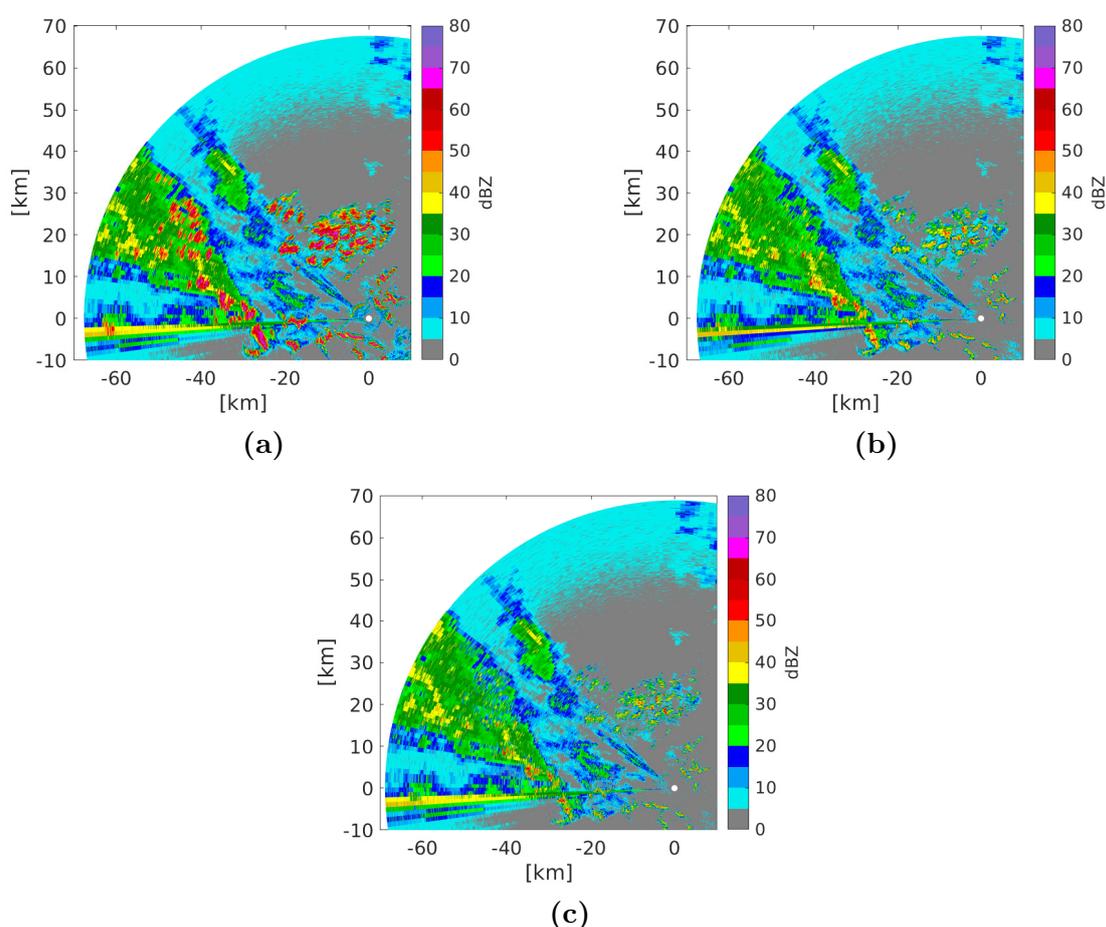


Figura 5.20: PPI de la reflectividad. (a) Aplicando PPP. (b) Aplicando GMAP. (c) Aplicando la DNN.

El procesamiento llevado a cabo sobre el conjunto de datos reales tiene por objetivo, en primer lugar, validar el desempeño de la DNN en la estimación de la velocidad Doppler media y ancho espectral en ausencia de clutter terrestre, y en segundo lugar, verificar el correcto funcionamiento de la estimación de los momentos espectrales en presencia del mismo. Con el objetivo de observar en detalle la zona donde se concentra la mayor parte del fenómeno y del clutter, los resultados de los siguientes gráficos se corresponden aproximadamente a 1/4 (90°) de un barrido completo (360°).

Las Figuras 5.20(a), 5.20(b) y 5.20(c) muestran el PPI de la reflectividad utilizando PPP, GMAP y la DNN, respectivamente. En la Figura 5.20(a) se observan zonas de diferentes valores de reflectividad. Las más intensas ($Z_{hh} \geq 50$) dBZ se corresponden al clutter terrestre, las de intensidades medias ($15 < Z_{hh} < 50$) dBZ al fenómeno meteorológico, y el resto al ruido. Como se mencionó en el Capítulo 4, las zonas de clutter se condicionan con las identificadas a partir del conocimiento geográfico de Bariloche. A partir de la Figura 5.20(b) se aprecia cómo GMAP elimina el clutter y recupera la reflectividad debida al fenómeno. En la Figura 5.20(c) se observa que la DNN identifica las zonas de clutter y estima la reflectividad del fenómeno, obteniéndose resultados comparables con GMAP. La homogeneidad que presenta la reflectividad alrededor de las zonas donde se removió el clutter indica que la estimación de la potencia del fenómeno meteorológico se encuentra en los órdenes esperados. Realizando una observación minuciosa en los valores de reflectividad obtenidos, se aprecia que tanto GMAP como la DNN presentan una región, aproximadamente a 170° en acimut, en la cual siguen quedando valores altos de reflectividad. Este resultado coincide con lo observado en la Sección 4.4 y se debe a la fuerte contribución del clutter que enmascara completamente al fenómeno.

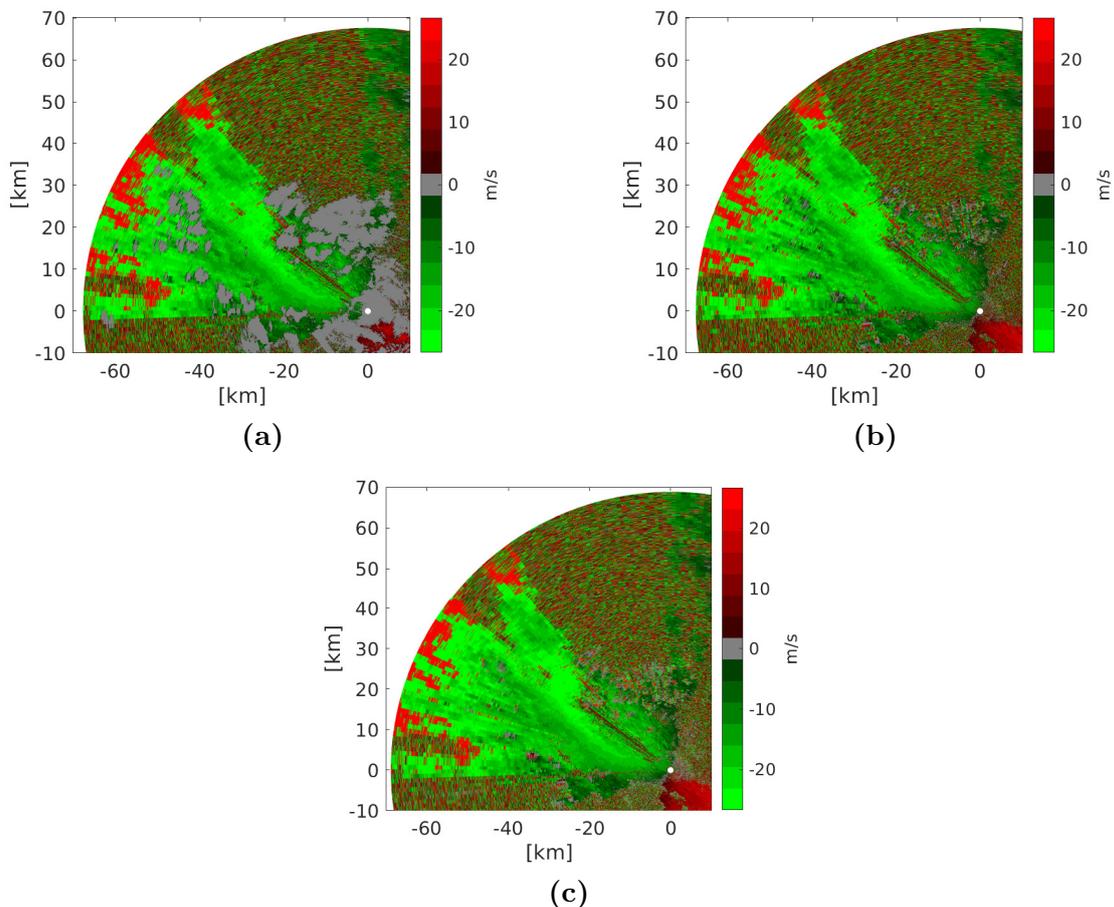


Figura 5.21: PPI de la velocidad Doppler media. (a) Aplicando PPP. (b) Aplicando GMAP. (c) Aplicando la DNN.

Las Figuras 5.21(a), 5.21(b) y 5.21(c) muestran el PPI de la velocidad Doppler media utilizando PPP, GMAP y la DNN. En la Figura 5.21(a) se observa que las zonas identificadas como clutter terrestre en el análisis de reflectividad poseen valores de velocidad en torno a cero, lo cual reafirma lo mencionado. Además, se advierten cambios abruptos en los valores de la velocidad, los cuales pasan de un extremo del intervalo Doppler hacia el otro. Estos saltos abruptos se deben al aliasing como consecuencia de que la velocidad máxima no ambigua correspondiente a estos datos, es menor que la velocidad del fenómeno en esas regiones. En la Figura 5.21(b) se observa que GMAP filtra el clutter y estima la velocidad del fenómeno.

Asimismo, dada la homogeneidad de los valores que muestra la Figura 5.21(c) y teniendo en cuenta que los resultados obtenidos son comparables a los de PPP y GMAP, se puede afirmar que la DNN estima de forma correcta la velocidad del fenómeno tanto en las zonas que presenta clutter como en aquellas en las que no posee sus contribuciones. Por otro lado, es importante mencionar que la DNN no resuelve el problema de los saltos abruptos en la velocidad Doppler estimada. Este comportamiento es consecuencia de que la red no puede incrementar el rango máximo no ambiguo debido a que la DEP que se emplea como entrada presenta efecto de replicado.

Las Figuras 5.22(a), 5.22(b), 5.22(c) muestran los PPIs del ancho espectral después de aplicar PPP, GMAP y la DNN, respectivamente. En las zonas identificadas como clutter los estimados obtenidos con PPP poseen valores bajos, como es de esperar para anchos espectrales de clutter terrestre. Este comportamiento es consecuencia de que en esas regiones el clutter es lo suficientemente intenso como para considerar despreciables las contribuciones de las demás señales involucradas. Para el fenómeno meteorológico los valores de σ_p se encuentran entre 1 m/s y 6 m/s. Valores mayores se corresponden a zonas de ruido o de fenómeno con baja SNR. De la Figura 5.22(b), se advierte como GMAP elimina las zonas de clutter y estima el ancho espectral. Estos valores son altos y se corresponden con los del ruido. En las zonas de clutter intenso, la SNR es muy baja, lo cual hace que GMAP estime valores sesgados. Por su parte, de la Figura 5.22(c) se observa que en las zonas de clutter la DNN presenta un comportamiento similar al de GMAP. Además, para las zonas de fenómeno y ruido sus valores son comparables a los de PPP y GMAP.

Con el presente estudio empleando mediciones de radar, se demuestra que la DNN entrenada con datos sintéticos es capaz de realizar estimaciones comparables con las de algoritmos establecidos y ampliamente utilizados como son PPP y GMAP. Se concluye que la DNN cumple satisfactoriamente el propósito con el que fue desarrollada. El éxito en el método propuesto radica en que los datos sintéticos generados utilizando modelos gaussianos para el clutter y el fenómeno constituyen una buena representación de los datos meteorológicos.

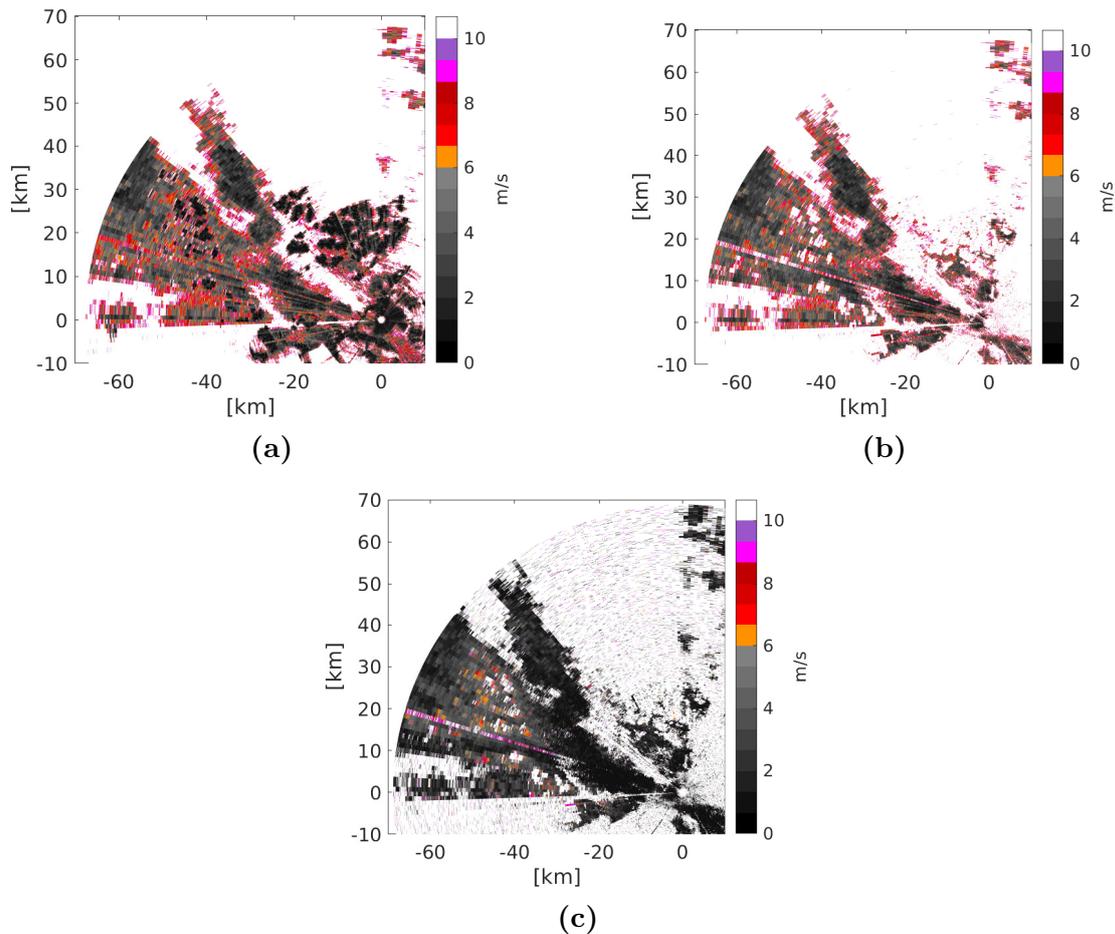


Figura 5.22: PPI del ancho espectral. (a) Aplicando PPP. (b) Aplicando GMAP. (c) Aplicando la DNN.

5.6. Conclusiones

En este capítulo se introdujo un método que utiliza una red neuronal profunda como solución a la estimación de momentos espectrales del fenómeno meteorológico. El método posee la ventaja de adaptar el procesamiento tanto a escenarios en los que existe clutter terrestre presente, como en los que no lo está, evitando la necesidad de contar con una etapa previa de identificación de clutter. Se propuso un diseño de DNN con tres ramas, donde cada rama estima uno de los siguientes parámetros: CSR_p , v_p y σ_p , respectivamente.

Una de las características novedosas que posee el método propuesto es que usa datos sintéticos para entrenar la red. Esto último está sustentado en el hecho de que el modelo matemático usado para generar los datos sintéticos se ajusta satisfactoriamente a las mediciones de los radares meteorológicos. Con esta forma de entrenar se pueden generar grandes bases de datos, abarcando de esta forma, la mayoría de las configuraciones meteorológicas posibles.

Una vez presentado el algoritmo, se describió la forma de generar los datos de entre-

namiento y validación. Para ello, se divide el espacio de parámetros en grillas discretas unidimensionales formando en su conjunto una grilla tetradimensional, en la cual, cada punto se corresponde a una situación meteorológica diferente. Posteriormente, se realizó un estudio de 15 redes totalmente conectadas, variando el número de capas ocultas y de neuronas por capa. Para el estudio se usaron las métricas: accuracy, tiempo de entrenamiento y tiempo de predicción. Del mismo, se seleccionó la red de mayor desempeño utilizando los datos de validación. Además, se compararon los tiempos tanto de entrenamiento como de predicción empleando la CPU y la GPU, concluyendo que conviene utilizar la GPU en ambas situaciones, principalmente si la red presenta un gran número de parámetros a entrenar. Después de seleccionar una arquitectura de red entre las 15 estudiadas, se reentrenó la misma utilizando conjuntos de entrenamiento y validación más amplios (con mayor número de realizaciones por configuración meteorológica que para el estudio de las 15 redes).

En la etapa de validación no sólo se utilizaron las métricas habituales de este tipo de herramientas, es decir accuracy y la función de loss, sino que también se incluyeron estudios que evalúan el error de índices en la diferencia entre las clases que predice la DNN y las verdaderas. El motivo de incluir esta nueva métrica radica en la naturaleza del problema. Se puede decir que se está resolviendo un problema de estimación como un problema de clasificación. En ese sentido aún cuando haya error en la clase elegida, esto no necesariamente implica un error grande en la estimación. La magnitud del error dependerá de la distancia entre la clase de salida y la clase verdadera. Combinando los análisis se observó que para las tres ramas, el error en la predicción posee forma de campana gaussiana, angosta, centrada en cero, lo cual, es un resultado deseado.

Una vez entrenada la red, se procedió a evaluar el desempeño de la misma en la estimación de los momentos espectrales. Para ello, el estudio se dividió en dos etapas: en la primera, se emplean simulaciones de tipo Monte Carlo con datos sintéticos, y en la segunda se utilizan mediciones adquiridas con el radar RMA-12. La primera etapa, se divide en dos escenarios: el primero contempla únicamente la presencia de fenómeno y ruido, y el segundo contempla la presencia de clutter contaminando la señal. Para ambos escenarios se llevan a cabo diferentes experimentos, en los cuales se toman el sesgo y la desviación estándar de las estimaciones como métricas. Además, se compara el desempeño de la DNN con: PPP para el primer escenario, y con GMAP para el segundo escenario. En el primer escenario se lleva a cabo un experimento, en el cual se fija el valor de la velocidad $v_p = 0$ m/s y se varían σ_p y SNR . Los resultados obtenidos son satisfactorios y comparables con PPP. Para el segundo escenario se llevan a cabo 3 experimentos, en los cuales, se estudia el desempeño de las estimaciones en función de la velocidad Doppler media, variando σ_p , CSR y SNR , respectivamente. Los resultados obtenidos en general son alentadores, siendo la estimación de la velocidad y del ancho espectral mejores que las de GMAP en los tres experimentos. Por el contrario,

la estimación de potencia del fenómeno arrojó resultados con errores altos llegando a ser en algún caso el doble de los obtenidos con GMAP. Este comportamiento es consecuencia de la propagación de errores debido a que el estimador de potencia del fenómeno depende de las estimaciones de potencia de clutter y de CSR_p , siendo su relación con este último de forma exponencial.

Un aspecto importante a destacar, consiste en que la DNN posee la capacidad de estimar los momentos espectrales sobre mediciones que se encuentren afectadas por clutter terrestre como en su ausencia. Implícitamente realiza una identificación, y más allá de la situación que se presente busca resolver cuáles son los parámetros del fenómeno meteorológico presente. Esto es una diferencia importante con respecto a PPP y GMAP. Por ejemplo, PPP no está diseñado para operar cuando existe clutter presente y en general cuando lo está sus estimaciones se sesgan considerablemente. Por otro lado, cuando se aplica GMAP a datos que no poseen clutter presente, la remoción de parte del espectro de forma innecesaria lleva a sesgos en la estimación de los momentos espectrales del fenómeno. La DNN puede lidiar con ambos escenarios, sin embargo esta versatilidad tiene el costo de que en algunas situaciones particulares se confunde, por ejemplo, cuando la velocidad del fenómeno es cercana a cero y no existe clutter presente. Más allá de esta salvedad, el desempeño mostrado por la DNN es aceptable teniendo en cuenta el balance entre desempeño y funcionalidades. Por otro lado, siempre se pueden lograr mejoras adicionales ampliando los escenarios en el entrenamiento o bien analizando otras arquitecturas posibles.

Por último, se validó el desempeño de la DNN utilizando mediciones reales de radar meteorológico adquiridas con el radar argentino RMA-12 ubicado en el aeropuerto de la ciudad de San Carlos de Bariloche. En general, se observaron buenos resultados, los mismos comparables con los obtenidos utilizando PPP y GMAP. Se verificó la capacidad del método propuesto de funcionar correctamente en ausencia y presencia del clutter terrestre. La DNN una vez entrenada, posee una carga computacional moderada y presenta la ventaja de procesar todos los datos en bloques (varios CPIs y todos los radiales), haciendo al método un buen candidato para implementaciones en tiempo real.

Como se mencionó la red fue entrenada con datos sintéticos y mostró un buen desempeño con datos reales. Con este tipo de herramientas esta característica es una gran ventaja y lleva a considerar una serie de pasos futuros que producirían una mejora en el desempeño y le daría robustez. Hasta el momento, los datos de entrenamiento responden al modelo gaussiano para la DEP del fenómeno meteorológico. Sin embargo, cerca del 25% de las mediciones obtenidas con radares meteorológicos se desvían del modelo gaussiano presentado para la DEP del fenómeno [7]. Por lo tanto, una línea consiste en estudiar modelos estadísticos, que contemplen espectros con formas no gaussianas, y que se ajusten a los datos, de modo de generar una gama más amplia

de datos sintéticos para emplear en la etapa de entrenamiento de la red. Además, esta flexibilidad también lo hace atractivo para considerar otros tipos de clutter que afectan a la señal (marítimo, eólico, biológico por citar algunos ejemplos). Estas dos alternativas en general no son tenidas en cuenta por los métodos convencionales, como ser GMAP.

Por otro lado, sin perjuicio de lo anterior, como trabajo futuro también es interesante contemplar la posibilidad de utilizar mediciones reales de radar en el entrenamiento. Por este motivo, con el objetivo de combinarlos con los modelos sintéticos, una posibilidad consiste en emplear la técnica *transferencia del aprendizaje* (en inglés, *transfer learning*) [89]. Dicha técnica se basa en reentrenar la última capa de la DNN empleando datos bien etiquetados, obtenidos con radares meteorológicos. Esto permitiría obtener modelos entrenados más realistas, los cuales contemplen las particularidades de los datos que no cubran los datos sintéticos.

Capítulo 6

Procesamiento Doppler para el modo staggered empleando CNN

“El motivo no existe siempre para ser alcanzado, sino para servir de punto de mira.”

— JOSEPH JOUBERT

6.1. Introducción

Como se mencionó en la Sección 2.2.3 el modo de operación *staggered* permite resolver valores mayores de velocidades Doppler media, sin degradar el rango máximo no ambiguo. Por esta razón, su uso es habitual en situaciones en las que las tormentas poseen velocidades altas y se encuentran alejadas del radar. En general, debido a la separación temporal no uniforme que presentan las muestras de la señal resultante en la dimensión tiempo lento bajo este modo de operación, el procesamiento de la misma implica un grado de dificultad mayor que para el modo de operación convencional, con PRI uniforme.

El método introducido en el Capítulo 5 se aplicó a señales adquiridas en el modo convencional de operación del radar. En este capítulo se extienden esas ideas para tratar con señales *staggered*. Si bien el método puede ser generalizado para cualquier relación de las PRIs, el estudio se concentra en señales *staggered 2/3*. En esta oportunidad se utiliza una red neuronal convolucional (CNN) para resolver el problema de la estimación de los momentos espectrales, en situaciones que contemplan tanto la presencia como la ausencia de clutter terrestre. La CNN se diseña con tres ramas: la primera para la estimación de CSR, la segunda para la estimación de velocidad Doppler media, y la tercera para la estimación del ancho espectral. Para el entrenamiento se emplean datos sintéticos, contemplando una gran variedad de escenarios meteorológicos posibles

(diferentes valores de CSR , SNR , v_p y σ_p). También, se realiza un estudio de diferentes estructuras de CNNs con el objetivo de elegir la que mejor desempeño presente para el problema.

Métodos como GMAP-TD o ASPASS para la supresión del clutter requieren de una etapa previa de detección del mismo, para de esta forma no incurrir en un filtrado innecesario de la señal en caso de que el clutter no estuviese presente. De no ser así, aunque los algoritmos mencionados son adaptivos y reconstruyen la región filtrada del espectro de la señal, las estimaciones de los momentos espectrales se ven degradadas. Una de las ventajas de la metodología introducida en el Capítulo 5, es que permite operar tanto en escenarios con presencia de clutter terrestre como en su ausencia, ya que la CNN entrenada posee la capacidad de identificar la presencia o ausencia del clutter de forma implícita.

Para analizar el desempeño de la CNN entrenada se procede de igual manera que para los demás métodos presentados a lo largo de la tesis. Por un lado, se usan simulaciones numéricas de tipo Monte Carlo tomando el sesgo y la desviación estándar de los estimadores de los momentos espectrales como métricas. Además, se compara el desempeño de la CNN con otros métodos: SPPP y DA, para el caso de ausencia de clutter terrestre; y ASPASS en las situaciones donde el clutter contamina la señal meteorológica. En segundo lugar, se emplea la CNN en el procesamiento de datos reales del radar meteorológico RMA-12.

El capítulo está organizado de la siguiente manera. En la Sección 6.2 se formula el problema, se presenta el método y la generación de los datos de entrenamiento y de validación. En la Sección 6.3 se realiza el estudio para elegir la arquitectura que mejor desempeño presente a partir de los datos de validación. En la Sección 6.4 se analiza el desempeño de la red entrenada y se compara con otros algoritmos existentes. El procesamiento de datos reales usando la CNN se estudia en la Sección 6.5. Finalmente, en la Sección 6.6 se presentan conclusiones.

6.2. Formulación del problema

Como se mencionó en la Sección 4.2.1, para la estimación de la DEP se agregan ceros entre las muestras para conformar una señal cuyas muestras presenten una separación temporal uniforme, haciendo posible el posterior uso de la DFT. Debido a esta interpolación con ceros, en el espacio transformado además de los espectros originales del clutter y del fenómeno, para *staggered 2/3*, surgen 4 réplicas por cada espectro original. Estos últimos, para el clutter y el fenómeno se centran en las velocidades Doppler 0 m/s y v_p , respectivamente; siendo la separación entre las réplicas de $0,4v_a$. Como consecuencia de esta estructura bien definida para la DEP de la señal *staggered*, surge la idea de poder estimar los momentos espectrales del fenómeno a partir de “observar” la

misma. Con el objetivo de ilustrar estas ideas, la Figura 6.1 muestra ejemplos de densidades espectrales de potencia. Cada subfigura se corresponde a una DEP estimada a partir de la generación de datos sintéticos, cuyos parámetros generales de simulación son: $v_a \approx 53,6$ m/s, $\sigma_t = 0,3$ m/s, $M = 64$ y $SNR = 20$ dB. En la descripción de cada subfigura se presenta la información específica de los parámetros correspondientes al fenómeno y al clutter terrestre.

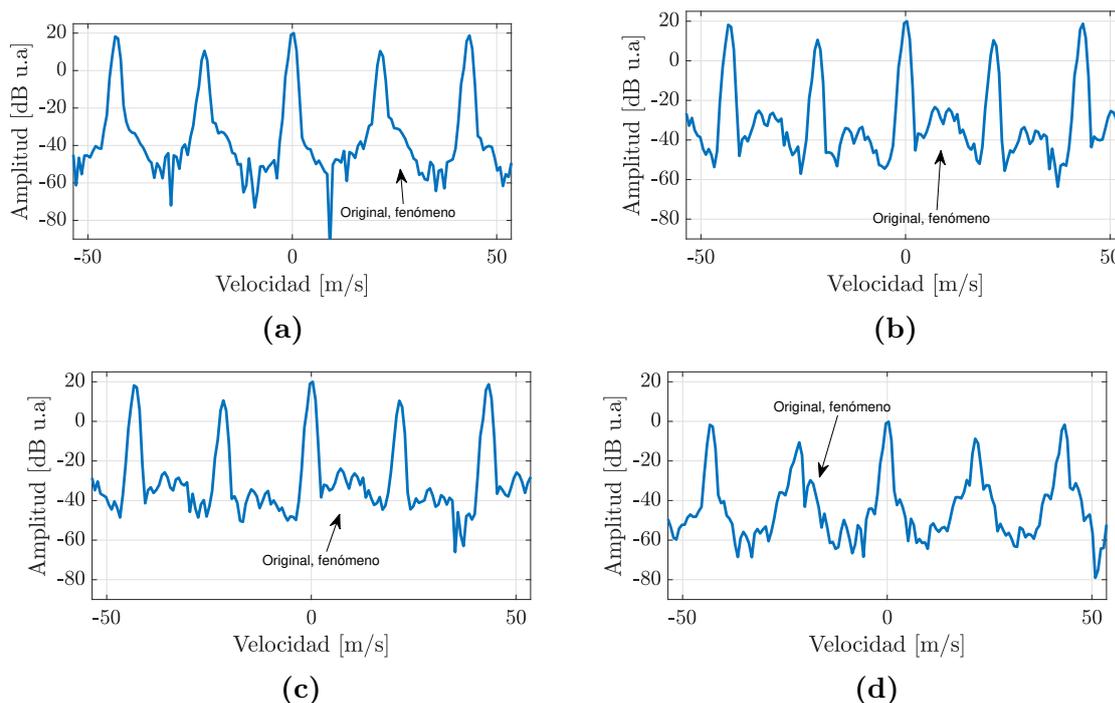


Figura 6.1: Ejemplo de DEPs en modo *staggered* 2/3. (a) $v_p = 0,4v_a$ m/s, $\sigma_p = 3$ m/s, $CSR = 40$ dB. (b) $v_p = 0,2v_a$ m/s, $\sigma_p = 3$ m/s, $CSR = 40$ dB. (c) $v_p = 0,2v_a$ m/s, $\sigma_p = 5$ m/s, $CSR = 40$ dB. (d) $v_p = -0,4v_a$ m/s, $\sigma_p = 2$ m/s, $CSR = 20$ dB.

Es importante destacar que existe un incremento en la complejidad del problema a resolver con respecto al modo de operación convencional. Por un lado, con la aparición de las réplicas de los espectros, en primera instancia el algoritmo debe ser capaz de identificar el espectro original del fenómeno meteorológico y sobre la base de esa elección realizar las estimaciones de los momentos espectrales. Esto es particularmente sensible para la estimación de la velocidad Doppler media, porque este parámetro dará un valor sesgado aún cuando el error en la réplica elegida sea con una réplica del espectro del propio fenómeno. Este efecto se ve agravado por el enmascaramiento del espectro de fenómeno por la superposición con una réplica del espectro del clutter, tal como se esquematiza en las Figuras 6.1(a) y 6.1(d). Por otro lado, con la nueva estructura de la DEP también aumenta significativamente el piso de la DEP, debido a la superposición de las colas de las réplicas. Esta situación se observa en la Figura 6.1(c), para la cual σ_p es igual 5 m/s. Esto implica una dificultad aún mayor al momento de realizar la identificación del espectro original.

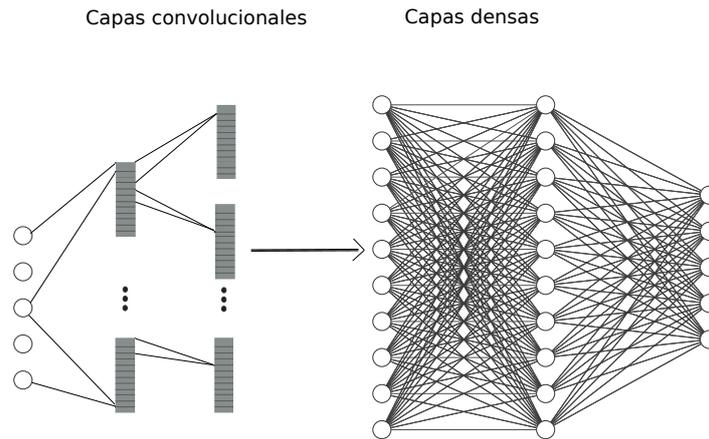


Figura 6.2: Arquitectura general de la CNN.

Siguiendo un enfoque análogo al descrito en el Capítulo 5, a continuación se utilizan redes neuronales convolucionales en la estimación de los momentos espectrales de los fenómenos meteorológicos para el modo de operación del radar con PRI *staggered*, contemplando situaciones tanto en presencia de clutter como en su ausencia.

6.2.1. Descripción del algoritmo

Al igual que para el modo convencional, se utiliza un esquema de clasificación y se diseña una red neuronal con tres ramas: la primera para la estimación de la CSR, la segunda para la estimación de velocidad, y la tercera para la estimación del ancho espectral. En esta oportunidad, para cada rama, se propone utilizar redes convolucionales de una dimensión, a diferencia de solamente las redes densas adoptadas en el Capítulo 5.

La Figura 6.2 muestra el diagrama general de una red convolucional, donde se observan las capas convolucionales de una dimensión seguidas de capas densas. Los números de capas ocultas y de neuronas por capa se definen cuando se estudia la arquitectura de la red en la Sección 6.3. El diagrama de flujo del algoritmo es el mismo que el presentado en la Sección 5.2.1. Se toma como entrada a la red una estimación de la DEP de la señal meteorológica, normalizada respecto de su valor máximo y expresada en escala logarítmica. En su estimación se usa ventana de Kaiser, siendo $\alpha = 8$, con el objetivo de disminuir los lóbulos secundarios del clutter, si el mismo estuviese presente.

6.2.2. Generación de los datos de entrenamiento y validación

Debido a las limitaciones para recolectar datos reales bien etiquetados mencionadas en la Sección 5.2.2, nuevamente, se propone usar datos sintéticos para entrenar y validar la red. Este procedimiento permite recrear cualquier escenario meteorológico variando los diferentes parámetros del modelo de datos para el clutter, el fenómeno y el ruido. El

valor de σ_t se fija a partir de los parámetros con los que se adquirieron los datos reales del radar RMA-12, que son utilizados en la Sección 6.5 para validar el desempeño de la red neuronal, resultando: $\sigma_t = \frac{4\sqrt{\ln(2)}}{5\pi M} v_a = 0,0033v_a$.

En esta oportunidad se divide el espacio de parámetros en una grilla tetradimensional, que contempla la mayor cantidad de valores de interés con una separación razonable entre ellos. Cada dimensión corresponde a uno de los siguientes parámetros: CSR , SNR , v_p y σ_p . Para CSR , se eligen 25 valores separados uniformemente en el intervalo de 0 dB a 50 dB. Además, se incluye la situación donde no existe clutter terrestre ($CSR \rightarrow -\infty$), conformando un total de 26 clases para la CSR . Para SNR se eligen 10 elementos uniformemente espaciadas en el intervalo 0 dB a 30 dB. En el caso de σ_p se eligen $N_o^{\sigma_p} = 10$ clases, en el rango de $0,04v_a$ a $0,2v_a$. Para v_p se usa una grilla de $N_o^{v_p} = 50$ clases, en el rango $-1 + \frac{1}{50}$ a $1 - \frac{1}{50}$ de v_a . Las elecciones de los rangos y valores de las grillas están basados en la experiencia de tratar con señales meteorológicas y conforme diversas pruebas que se realizaron sobre mediciones reales. Cabe mencionar que el intervalo para σ_p se redujo a la mitad respecto de lo realizado para el modo de operación convencional. Esta elección está basada en la gran superposición que existe entre las réplicas del fenómeno para mayores valores de σ_p , que conlleva el incremento en el piso del espectro.

Las divisiones anteriores resultan en una grilla tetradimensional de 130000 puntos, donde cada uno representa una situación meteorológica diferente. Para cada caso, excepto cuando $CSR \rightarrow -\infty$, se generan 5 realizaciones de series temporales de datos IQ, obteniendo de esta forma 5 DEPs para una misma situación meteorológica, cada una con $M = 64$ muestras por CPI. Para el caso $CSR \rightarrow -\infty$ se generan 40 realizaciones de series temporales de datos IQ. La elección anterior está basada en que existen 25 clases donde el clutter se encuentra presente y solo una donde está ausente. Además, porque se requiere entrenar la red para que procese escenarios con y sin la presencia de clutter con buen desempeño en ambas situaciones y para ello se debe tener en cuenta que, como se mencionó en la Sección 5.2.2 en la mayoría de las situaciones de interés utilizando mediciones meteorológicas reales, la señal no está contaminada por clutter terrestre. Dado el grillado anterior y el número de realizaciones, en total, el conjunto de datos de entrenamiento contiene 825000 DEPs.

Para los datos de validación se utilizó un grillado diferente para la SNR . Se eligieron 15 puntos separados uniformemente en el intervalo 0 dB a 30 dB, mientras que las grillas CSR , v_p y σ_p permanecen igual que en la generación de los datos de entrenamiento. Para esta nueva división del parámetro SNR , se cuenta en total con 195000 configuraciones meteorológicas diferentes. En este caso, para cada situación meteorológica se generan 24 realizaciones de series temporales de datos IQ cuando $CSR \rightarrow -\infty$, y 3 realizaciones cuando $CSR \geq 0$, lo que implica un total de 742500 DEPs.

6.3. Estudio de arquitecturas convolucionales

En esta sección se estudia el desempeño de diferentes arquitecturas de redes neuronales convolucionales de diferentes tamaños. El objetivo es encontrar entre las redes estudiadas, la que presente el mejor desempeño para los datos de validación. La Tabla 6.1 muestra el número de núcleos y sus longitudes para cada capa convolucional, y también el número de neuronas para cada capa densa de las 12 arquitecturas propuestas. La notación x, y en las capas convolucionales de una dimensión (conv1d) representa “ x núcleos de longitud y ”.

Las 12 arquitecturas se entrenan usando los mismos hiperparámetros, librerías y hardware utilizado en la Sección 5.3, excepto que en esta oportunidad para el criterio early stopping se monitorea la función de loss en la validación, tal que la misma no supere en 0,005 del mínimo valor obtenido.

Para realizar la comparación entre las arquitecturas se usan las métricas loss, accuracy y tiempo de predicción. En la Figura 6.3 se observan los resultados del estudio usando los datos de validación para las 12 arquitecturas. Las Figuras 6.3(a) y 6.3(b) muestran la función de loss y el accuracy para cada rama, respectivamente. Si bien todas las arquitecturas presentan un desempeño comparable, se aprecia que las arquitecturas 10 y 12 presentan los mayores valores de accuracy para las tres ramas. Por otro lado, de la Figura 6.3(c) se observa que el tiempo promedio de predicción de la arquitectura 10 es 23% menor que el de la arquitectura 12. Para el cálculo de estos tiempos, se utilizaron 3 corridas para cada arquitectura.

Por los resultados mostrados, dado que todas las arquitecturas presentan valores de accuracy comparables, a la hora de elegir una arquitectura el tiempo de predicción será el factor discriminante. En consecuencia, para el resto del capítulo, se elige la arquitectura número 10 para resolver el problema de estimación de los momentos espectrales del fenómeno.

6.3.1. Entrenamiento y validación de la arquitectura elegida

A continuación se estudia en detalle el entrenamiento y la validación de la arquitectura número 10, a la cual se llamará CNN a lo largo de lo que resta del capítulo. La Figura 6.4 muestra el desempeño del entrenamiento y la validación en función del número de épocas. En la Figura 6.4(a) se observa la función de loss, mientras que en la Figura 6.4(b) se observa el accuracy. De ambas se aprecia que para el entrenamiento y la validación, las funciones de loss disminuyen y los valores de accuracy aumentan con el número de épocas. Esto indica que la CNN aprende a predecir las clases de forma correcta.

De la Figura 6.4(b) se identifica que los valores de accuracy de validación para las

Arquitectura	Ramas	conv1d	conv1d	conv1d	conv1d	conv1d	densa	densa	densa	densa
1	v_p	3,20					80	60		
	σ_p	3,20					80	40		
	CSR_p	3,20					80	50		
2	v_p	6,20					80	60		
	σ_p	6,20					80	40		
	CSR_p	6,20					80	50		
3	v_p	3,20					150	100		
	σ_p	3,20					150	80		
	CSR_p	3,20					150	90		
4	v_p	6,20					150	100		
	σ_p	6,20					150	80		
	CSR_p	6,20					150	90		
5	v_p	3,20	6,20				80	60		
	σ_p	3,20	6,20				80	40		
	CSR_p	3,20	6,20				80	50		
6	v_p	3,20	6,20				150	100		
	σ_p	3,20	6,20				150	80		
	CSR_p	3,20	6,20				150	90		
7	v_p	3,20	6,20	9,20			80	60		
	σ_p	3,20	6,20	9,20			80	40		
	CSR_p	3,20	6,20	9,20			80	50		
8	v_p	3,20	6,20	9,20			150	100		
	σ_p	3,20	6,20	9,20			150	80		
	CSR_p	3,20	6,20	9,20			150	90		
9	v_p	6,20	9,15	12,10			80	60		
	σ_p	6,20	9,15	12,10			80	40		
	CSR_p	6,20	9,15	12,10			80	50		
10	v_p	5,5	5,5	5,5			100	80	60	
	σ_p	5,5	5,5	5,5			100	80	40	
	CSR_p	5,5	5,5	5,5			100	80	50	
11	v_p	20,20	20,20	20,20			200	100	60	
	σ_p	20,20	20,20	20,20			200	100	40	
	CSR_p	20,20	20,20	20,20			200	100	50	
12	v_p	5,5	5,5	5,5	5,5	5,5	200	100	100	60
	σ_p	5,5	5,5	5,5	5,5	5,5	200	100	100	40
	CSR_p	5,5	5,5	5,5	5,5	5,5	200	100	100	50

Tabla 6.1: Arquitecturas convolucionales

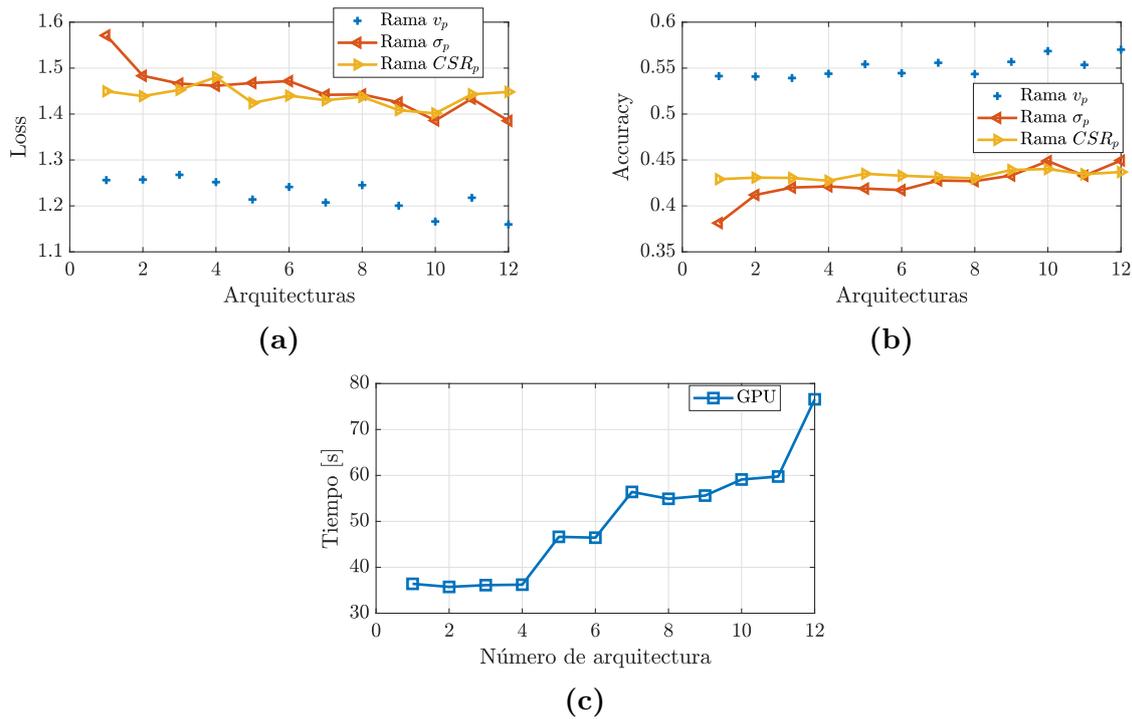


Figura 6.3: Estudio de diferentes redes convolucionales. (a) Loss. (b) Accuracy. (c) Tiempo de predicción.

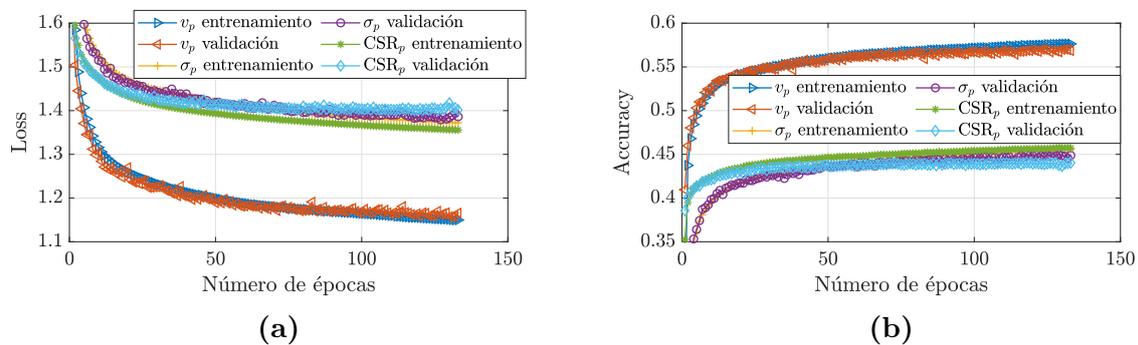


Figura 6.4: Desempeño del entrenamiento y la validación de la CNN. (a) Loss. (b) Accuracy.

ramas v_p , σ_p y CSR_p son aproximadamente, 0,57, 0,45 y 0,44, respectivamente. Como se mencionó en la Sección 5.3.1 la métrica accuracy penaliza por igual, ya sea que se cometa un error de una clase con su vecina o bien entre varias clases alejadas. Por esta razón, con el motivo de profundizar sobre la validación de la CNN entrenada, se propone como métrica calcular la diferencia entre los índices de las clases que predice la CNN y las verdaderas.

Las Figuras 6.5(a), 6.5(b) y 6.5(c) muestran los histogramas de los errores de clases para las ramas v_p , σ_p y CSR_p , respectivamente. Es importante mencionar que con la elección de la grilla tetradsimensional realizada en la Sección 6.2.2, la distancia entre dos clases consecutivas para las ramas v_p , σ_p y CSR_p , se corresponde a $0,04v_a$, $0,018v_a$ y $2,08$ dB, respectivamente. La Figura 6.5(a) permite concluir que más del 90% de

las predicciones se encuentran a lo sumo a una clase de diferencia. La distribución de los errores de clases tiene forma aproximadamente gaussiana, centrada en cero. Esto sugiere que la estimación de velocidad resulta insesgada. Los errores que se observan a aproximadamente ± 25 se corresponden a situaciones en las que la red se confunde con alguna de las réplicas del espectro, por otro lado, los errores en ± 50 se corresponden a la situación en las que v_p toma valores cercanos a $\pm v_a$. No obstante, la probabilidad de ocurrencia que muestran estos dos resultados, a los fines prácticos, es baja. De las Figuras 6.5(b) y 6.5(c) se aprecia que mas del 70 % de los errores se encuentran a lo sumo a una clase de diferencia, y que la distribución de los errores de clases también poseen forma gaussiana, centrada en cero.

El último análisis muestra que la CNN entrenada en caso de equivocarse el error de la diferencia de clases es bajo, lo que conlleva que los errores en la estimación de los parámetros, en general, sean pequeños. Los errores resultantes poseen densidades de probabilidad (aproximadas por los histogramas) centradas en cero, lo que indica que poseen bajos valores de sesgo, y, además, tienen forma de campana angosta, lo que muestra que la dispersión es pequeña.

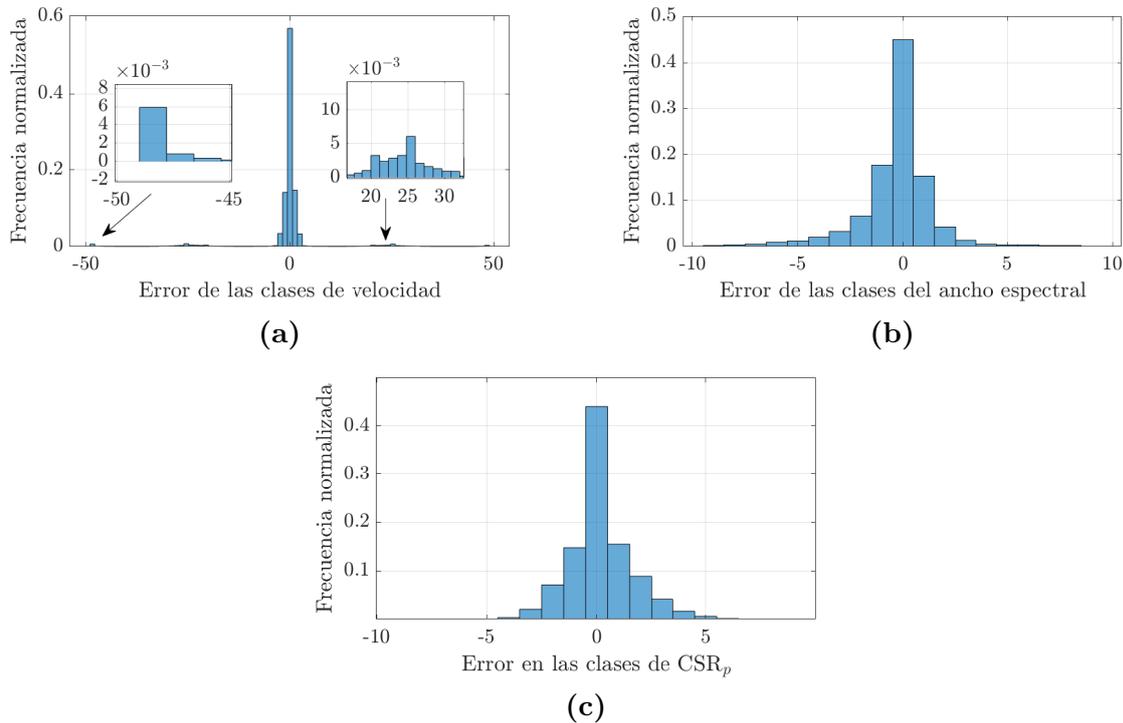


Figura 6.5: Histogramas de los errores de clases. (a) Rama v_p . (b) Rama σ_p . (c) Rama CSR_p .

6.4. Experiencias con datos sintéticos

En esta sección se estudia el desempeño de la CNN por medio de simulaciones numéricas a partir de diferentes experimentos. Dada la capacidad que presenta el méto-

do de detectar la presencia de clutter terrestre, se consideran dos escenarios: el primero, cuando el clutter no está presente en la señal meteorológica; y el segundo, cuando el clutter contamina la señal. También se estudia el desempeño de otros algoritmos, y se comparan con el de la CNN. Para el primer escenario, se compara con el desempeño del algoritmo DA en la estimación de velocidad, descrito en la Sección 2.5.2, y con SPPP en la estimación del ancho espectral, descrito en la Sección 2.5.1. Por otro lado, para el segundo escenario se compara con el desempeño de ASPASS, introducido en el Capítulo 4. Los parámetros generales de las simulaciones se presentan en la Tabla 6.2

Los experimentos consisten en variar dos o tres parámetros en simultáneo, evaluando en cada caso los estimados de los momentos espectrales. Los conjuntos de parámetros se toman entre la CSR, la SNR, la velocidad Doppler media y el ancho espectral. El sesgo y la desviación estándar (std) se toman como métricas de desempeño.

Parámetro	Símbolo	Valor
Frecuencia de portadora	F_c [GHz]	5,6
Longitud de onda	λ [cm]	5,35
Nro. de muestras (pulsos)	M	64
PRI 1	T_1 [ms]	0,5
PRI 2	T_2 [ms]	0,75
Velocidad máxima no ambigua	v_a [m/s]	53.6
Potencia del fenómeno	p_p [u.a.]	1

Tabla 6.2: Parámetros para la simulación.

6.4.1. Desempeño de la CNN en ausencia de clutter terrestre

Teniendo en cuenta que la ausencia de clutter terrestre es una situación muy frecuente en práctica, la CNN fue diseñada con la capacidad de procesar la señal radar en estas condiciones para estimar la velocidad Doppler media y el ancho espectral. Por ese motivo, en esta sección se evalúa el desempeño de la CNN en ese escenario. Para llevar a cabo el experimento, se fija $v_p = 12$ m/s y se varía σ_p de $\sigma_p = 0,04v_a = 2,14$ m/s a $\sigma_p = 0,2v_a = 10,7$ m/s utilizando 3 valores distintos de SNR: 10 dB, 15 dB y 20 dB. Para cada valor de σ_p y SNR, se generan 1000 realizaciones diferentes de datos IQ.

En la Figura 6.6 se presentan los resultados del análisis de error en las estimaciones de velocidad Doppler media y del ancho espectral. En la Figura 6.6(a) se observa que, para los tres valores de SNR utilizados, el sesgo es aproximadamente cero hasta $\sigma_p \approx 6$ m/s. En ese rango de valores de σ_p se puede considerar que tanto la CNN como DA arrojan estimaciones insesgadas. Para valores mayores de ancho espectral se produce

un quiebre en el comportamiento llevando a que el sesgo en las estimaciones de DA para $SNR = 10$ dB se incremente rápidamente. Este comportamiento se replica para los demás valores de SNR a medida que se incrementa σ_p . Cabe destacar que para la CNN también se aprecia el comportamiento anterior, pero los valores de σ_p en los cuales se manifiesta, para un mismo valor de SNR , son mayores que para DA. De cualquier manera, para ambos métodos los valores de ancho espectral para los que el sesgo se incrementa son elevados. De la Figura 6.6(b) se observa que la CNN presenta menores valores de std que DA en todo el intervalo de σ_p analizado y para los tres valores de SNR . Este resultado es muy satisfactorio, ya que el algoritmo DA es uno de los mejores estimadores de velocidad Doppler media para escenarios con medianos y altos valores de SNR [30].

Por su parte, para la estimación del ancho espectral, de la Figura 6.6(c) se observa que SPPP, cuando $SNR = 10$ dB, presenta sesgo para todos los valores de σ_p , mientras que la CNN presenta un comportamiento aproximadamente insesgado hasta $\sigma_p \approx 4$ m/s y para valores mayores σ_p muestra un sesgo significativamente menor que el de los estimados de SPPP. A medida que aumenta la SNR el sesgo de los estimados de SPPP disminuye, en el caso de la CNN mantiene en módulo un sesgo del mismo orden para todos los valores de SNR . Con respecto a la std, de la Figura 6.6(d) las variaciones son del mismo tipo para ambos métodos. Sin embargo, al igual que para la estimación de velocidad, se aprecia que la CNN presenta menores valores de std que SPPP, para todos los valores de σ_p y de SNR analizados.

En general, de los resultados anteriores se concluye que la CNN presenta mejor desempeño que DA en la estimación de velocidad Doppler media y que SPPP en la estimación del ancho espectral. Una ventaja adicional de la CNN consiste en que fue diseñada para trabajar tanto con presencia como en ausencia de clutter, mientras que DA y SPPP fueron concebidos para operar cuando la señal se compone únicamente de contribuciones del fenómeno meteorológico más ruido, arrojando estimados muy sesgados frente a la presencia de clutter terrestre.

6.4.2. Desempeño de la CNN en presencia de clutter terrestre

En esta sección se estudia el desempeño de la CNN en el segundo escenario propuesto, es decir cuando existe clutter terrestre contaminando la señal meteorológica. En un primer experimento se analiza la estimación de los momentos espectrales en función de CSR , para dos valores distintos de velocidad y de ancho espectral. Además de la CNN, se utiliza el algoritmo ASPASS, con el objetivo de comparar ambos desempeños. Como se mencionó en la Sección 3.2 el ancho del clutter teórico depende de las propiedades físicas de la antena y ciertos parámetros de operación, lo cual hace que cada radar, en función del modo de operación, PRIs usadas y de los parámetros de adquisición

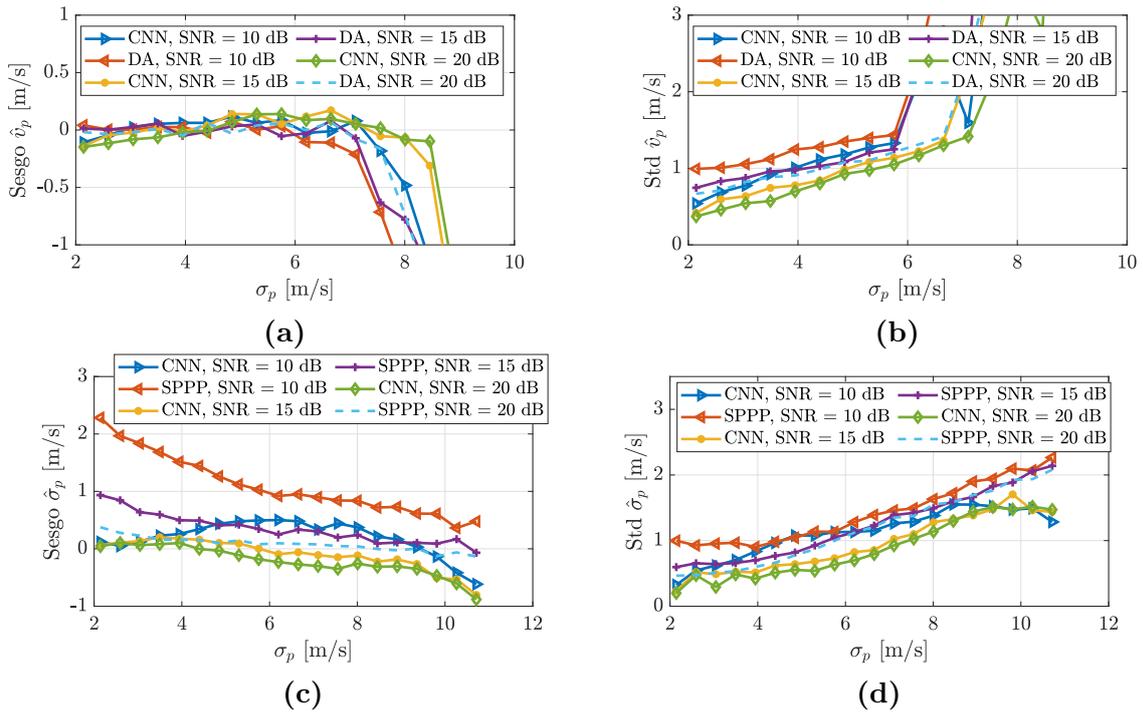


Figura 6.6: Análisis de error de las estimaciones en ausencia de clutter terrestre. (a) Sesgo en los estimados de velocidad. (b) Desviación estándar en los estimados de velocidad. (c) Sesgo en los estimados de ancho espectral. (d) Desviación estándar en los estimados de ancho espectral.

(M , λ) presente diferentes valores de σ_t . Por esta razón, en un segundo experimento se analiza el desempeño de la CNN en función de σ_t , de forma de determinar si es necesario reentrenar la CNN cuando la misma se usa para procesar señales que poseen diferentes valores de ancho teórico de clutter respecto del utilizado durante su entrenamiento. En los dos experimentos, para cada configuración meteorológica se contemplan 1000 realizaciones de datos IQ. En el caso de ASPASS se utiliza ventana de Kaiser con $\alpha = 8$. Los parámetros generales de las simulaciones se encuentran en la Tabla 6.2, considerando $\sigma_t = 0,0033v_a = 0,178$ m/s para el primer experimento.

Diferentes CSR

Para el primer experimento se utilizan dos valores de velocidad: $0,2v_a = 10,7$ m/s y $0,4v_a = 21,4$ m/s. Esta elección se basa en contar con situaciones donde no existe superposición entre las réplicas del fenómeno y del clutter, y situaciones donde sí existe dicha superposición. Además, por cada valor de velocidad se eligen dos valores de σ_p : 3 m/s y 5 m/s. Los valores de CSR se varían de 0 dB a 50 dB.

En la Figura 6.7 se muestra el análisis de error en la estimación de los momentos espectrales del fenómeno meteorológico. De las Figuras 6.7(a) y 6.7(b) se observa que la CNN y ASPASS arrojan estimaciones de potencia insesgadas desde el punto de vista práctico, y que ASPASS, en general, presenta menores valores de std en todo el intervalo de CSR analizado. Este resultado se debe principalmente a la manera de

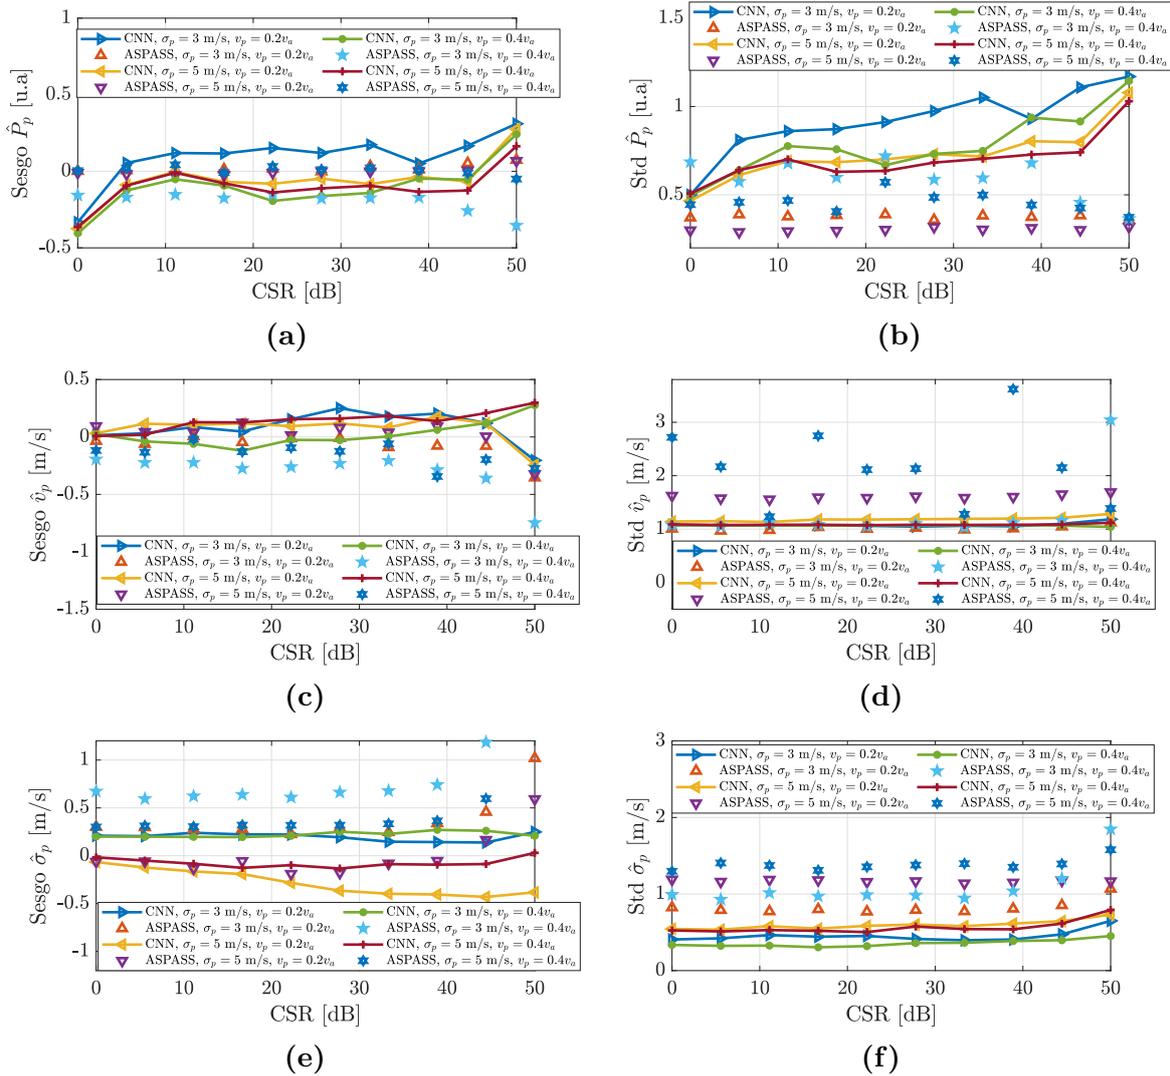


Figura 6.7: Análisis de error de las estimaciones en presencia de clutter terrestre. (a) Sesgo en los estimados de potencia. (b) Desviación estándar en los estimados de potencia (c) Sesgo en los estimados de velocidad. (d) Desviación estándar en los estimados de velocidad. (e) Sesgo en los estimados de ancho espectral. (f) Desviación estándar en los estimados de ancho espectral.

estimar p_p mediante la CNN, en la cual se involucran los estimados de \hat{S}_c y \widehat{CSR}_p , siendo la dependencia con este último de forma exponencial.

En el caso de la velocidad Doppler media, de las Figuras 6.7(c) y 6.7(d) se observa que ambos algoritmos reportan en general sesgos pequeños, aunque en el caso de ASPASS para la situación $\sigma_p = 3$ m/s y $v_p = 0.4v_a$ el sesgo aumenta debido a la superposición de los espectros del clutter y del fenómeno. Para la std, en general, la CNN presenta menores valores que ASPASS, y no se observa degradación en el desempeño debido a la superposición de los espectros del clutter y del fenómeno como en el caso de ASPASS.

Por su parte, para la estimación del ancho espectral, de la Figura 6.7(e) se observa por un lado que, para la CNN y $\sigma_p = 3$ m/s existe un pequeño sesgo constante, el cual está asociado, principalmente, a la discretización de valores del ancho espectral

utilizado en el diseño de la grilla de σ_p a la hora de entrenar la CNN. Además, para $\sigma_p = 5$ m/s y $v_p = 0,2v_a$ se aprecia sesgo a medida que aumenta CSR . Por otro lado, en ASPASS el sesgo es aproximadamente constante para todas las situaciones contempladas y es significativamente mayor cuando el valor de velocidad Doppler media es $0,4v_a$. Esto se debe a que para ese valor de velocidad el espectro del fenómeno es en parte removido en el filtrado debido a la superposición con una réplica del espectro del clutter. Para la std, de la Figura 6.7(f) se observa que la CNN presenta valores de dispersión que corresponden a aproximadamente la mitad de los de ASPASS para todas las configuraciones estudiadas, y que sus valores son aproximadamente constantes en el intervalo de CSR analizado.

En general, excepto para la estimación de potencia, los resultados de la CNN son mejores que los de ASPASS, cumpliendo de forma satisfactoria con los objetivos con los que fue desarrollado el algoritmo.

Diferentes σ_t

En el segundo experimento se evalúa el desempeño de la CNN en aquellas situaciones en el que los datos poseen valores de ancho teórico del clutter diferentes al empleado durante el entrenamiento. Para ello se fijan los valores: $CSR = 40$ dB, $SNR = 20$ dB. Además, se seleccionan dos valores de velocidad Doppler media, $v_p = 0,2v_a = 10,7$ m/s y $v_p = 0,4v_a = 21,4$ m/s; y dos valores de ancho espectral, $\sigma_p = 4$ m/s y $\sigma_p = 5$ m/s. Para cada parámetro variable se generan 1000 realizaciones de la señal IQ. Los valores de σ_t utilizados van desde $0,0015v_a = 0,08$ m/s hasta $0,01v_a = 0,53$ m/s.

En la Figura 6.8 se muestran los resultados del análisis de error en la estimación de los momentos espectrales del fenómeno en función de σ_t . De la Figura 6.8(a) se observa que la estimación de potencia es insesgada en la vecindad de $\sigma_t = 0,178$ m/s (línea vertical discontinua). Además se aprecia que el sesgo aumenta rápidamente al alejarse del valor teórico de ancho de clutter con el que fue entrenada la CNN. Para la std, de la Figura 6.8(b) se observa que los menores valores no se obtienen para $\sigma_t = 0,178$ m/s, sino alrededor de $\sigma_t = 0,35$ m/s. Este comportamiento indica que para esos valores la CNN, con mayor probabilidad, elige la misma clase de CSR_p , lo cual asegura estimaciones sesgadas pero con una dispersión pequeña.

Por su parte, para la estimación de velocidad de la Figura 6.8(c), a diferencia de la estimación de potencia, se observa que la CNN arroja valores insesgados desde el punto de vista práctico para $\sigma_t \leq 0,40$ m/s. También para la std, de la Figura 6.8(d) se aprecia que la degradación en la estimación no es significativa hasta $\sigma_t = 0,40$ m/s, siendo mayor para las situaciones en las que $v_p = 0,2v_a$.

En el caso del ancho espectral, de la Figura 6.8(e) se observa que los estimados presentan un sesgo mayor que los momentos espectrales de menor orden, presentando

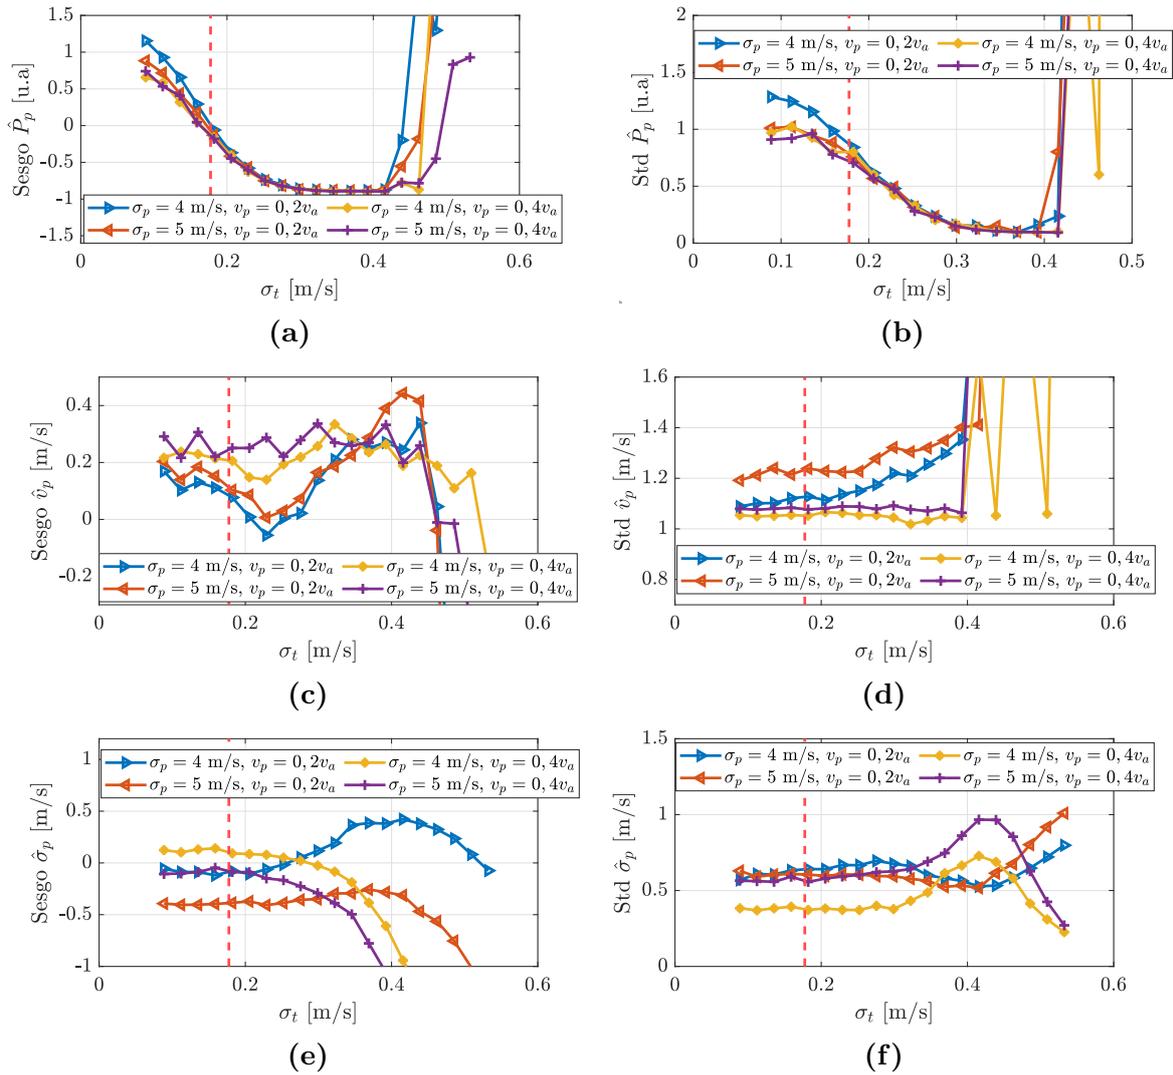


Figura 6.8: Análisis de error en las estimaciones de los momentos espectrales del fenómeno en función de σ_t . (a) Sesgo potencia. (b) Desviación estándar potencia (c) Sesgo velocidad. (d) Desviación estándar velocidad. (e) Sesgo ancho espectral. (f) Desviación estándar ancho espectral.

una variación diferente para cada situación considerada. En todos los escenarios, en la vecindad de $\sigma_t = 0,178$ m/s se mantiene constante tomando el menor valor, llegando a ser en el peor caso aproximadamente del 10% del valor de σ_p cuando $\sigma_p = 5$ m/s y $v_p = 0,2v_a$. Luego, a medida que aumenta σ_t respecto del valor de referencia el sesgo se incrementa en módulo. De la Figura 6.8(f) se aprecia que los valores de std se mantienen constante para todas las situaciones hasta $\sigma_t = 0,3$ m/s.

Los resultados anteriores indican que la CNN entrenada usando un valor de ancho de clutter teórico σ_{t_1} puede ser aplicada a señales radar que posean otro valor σ_{t_2} , siempre y cuando este nuevo valor no difiera mucho del primero. La afirmación anterior es rígida para la estimación de potencia, mientras que es más relajada para las estimaciones de velocidad Doppler media y ancho espectral, en las cuales se observó que la distancia entre σ_{t_1} y σ_{t_2} puede ser mayor y aún así lograr resultados comparables a los que se

obtienen cuando $\sigma_{t_1} \approx \sigma_{t_2}$.

6.5. Procesamiento de datos reales

En esta sección se emplea la CNN entrenada con datos sintéticos para estimar los momentos espectrales de mediciones adquiridas con el radar meteorológico RMA-12. Las PRIs son $T_1 = 0,5$ ms y $T_2 = 0,75$ ms, lo que equivale a una velocidad máxima no ambigua de $v_a = 53,33$ m/s.

El procesamiento llevado a cabo sobre el conjunto de datos reales tiene por objetivo, en primer lugar, validar el desempeño de la CNN en la estimación de la velocidad Doppler media y ancho espectral en ausencia de clutter terrestre, y en segundo lugar, verificar el correcto funcionamiento de la estimación de los momentos espectrales en presencia del mismo. Con el objetivo de observar en detalle la zona donde se concentra la mayor parte del fenómeno y del clutter, los resultados de los siguientes gráficos se corresponden aproximadamente a $1/4$ (90°) de un barrido completo (360°).

Las Figuras 6.9(a), 6.9(c) y 6.9(e) muestran el PPI de la reflectividad utilizando SPPP, ASPASS y la CNN, respectivamente, mientras que las Figuras 6.9(b), 6.9(d) y 6.9(f) muestran una ampliación de estos resultados en la región comprendida por los intervalos $[-57$ km, -30 km] en el eje horizontal y $[10$ km, 37 km] en el eje vertical. En la Figura 6.9(a) se observan zonas de diferentes valores de reflectividad. Teniendo en cuenta lo mencionado en la Sección 4.4 respecto de la geografía de Bariloche y la figura anterior, se identifican las zonas de clutter, las cuales se corresponden a valores altos de reflectividad. A partir de la Figura 6.9(c) se aprecia cómo ASPASS elimina el clutter y recupera la reflectividad debida al fenómeno. Comparando las Figuras 6.9(b) y 6.9(d) se aprecia mejor lo antes enunciado. En la Figura 6.9(e) se observa que la CNN identifica las zonas de clutter y estima la reflectividad del fenómeno, obteniéndose resultados comparables con los de ASPASS. La homogeneidad que presenta la reflectividad alrededor de las zonas donde se removió el clutter indica que la estimación de la potencia del fenómeno meteorológico se encuentra en los órdenes esperados. Observando en detalle las Figuras 6.9(d) y 6.9(f) se percibe que los valores obtenidos con la CNN presentan menor homogeneidad que los de ASPASS en las zonas de clutter, lo cual es esperado debido a que ASPASS presenta menor dispersión en la estimación de la potencia que la CNN, tal como se verificó en la Sección 6.4.

Las Figuras 6.10(a), 6.10(c) y 6.10(e) muestran el PPI de la velocidad Doppler media usando DA, ASPASS y la CNN, mientras que en las Figuras 6.10(b), 6.10(d) y 6.10(f) se muestra la misma ampliación aplicada a la reflectividad. En la Figura 6.10(a) se observa que las zonas identificadas como clutter terrestre en el análisis de reflectividad poseen valores de velocidad en torno a cero, lo cual reafirma lo mencionado. En la Figura 6.10(c) se aprecia que ASPASS filtra el clutter y estima la velocidad del

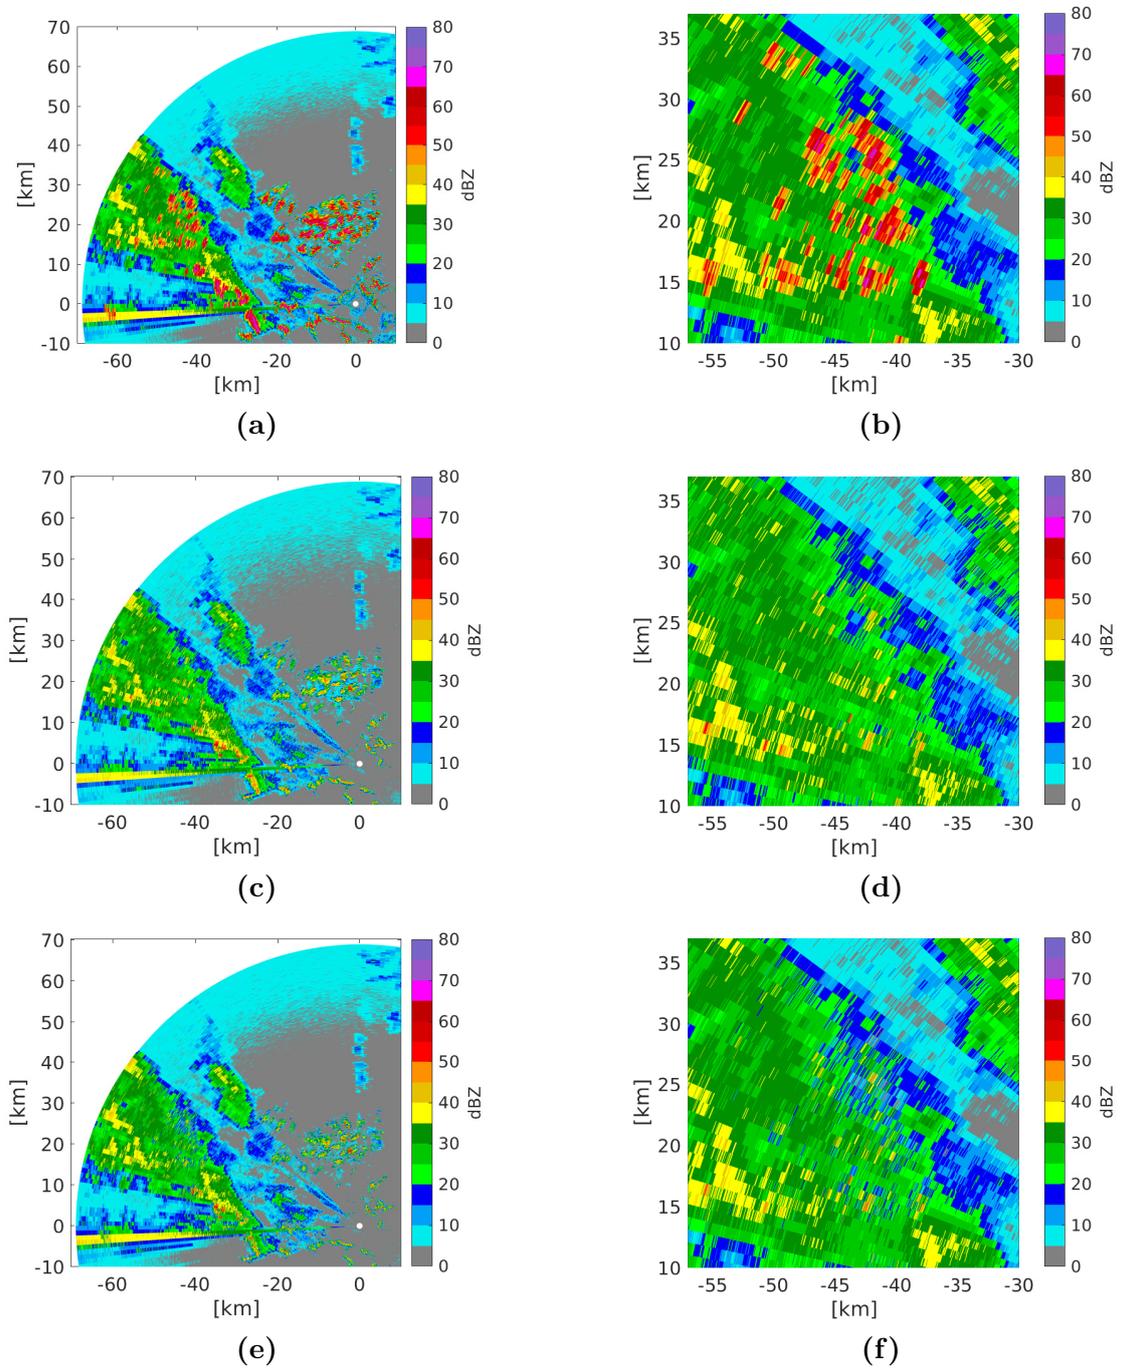


Figura 6.9: PPI de la reflectividad. (a) Aplicando SPPP. (b) Aplicando SPPP. (c) Aplicando ASPASS. (d) Aplicando ASPASS . (e) Aplicando la CNN. (f) Aplicando la CNN.

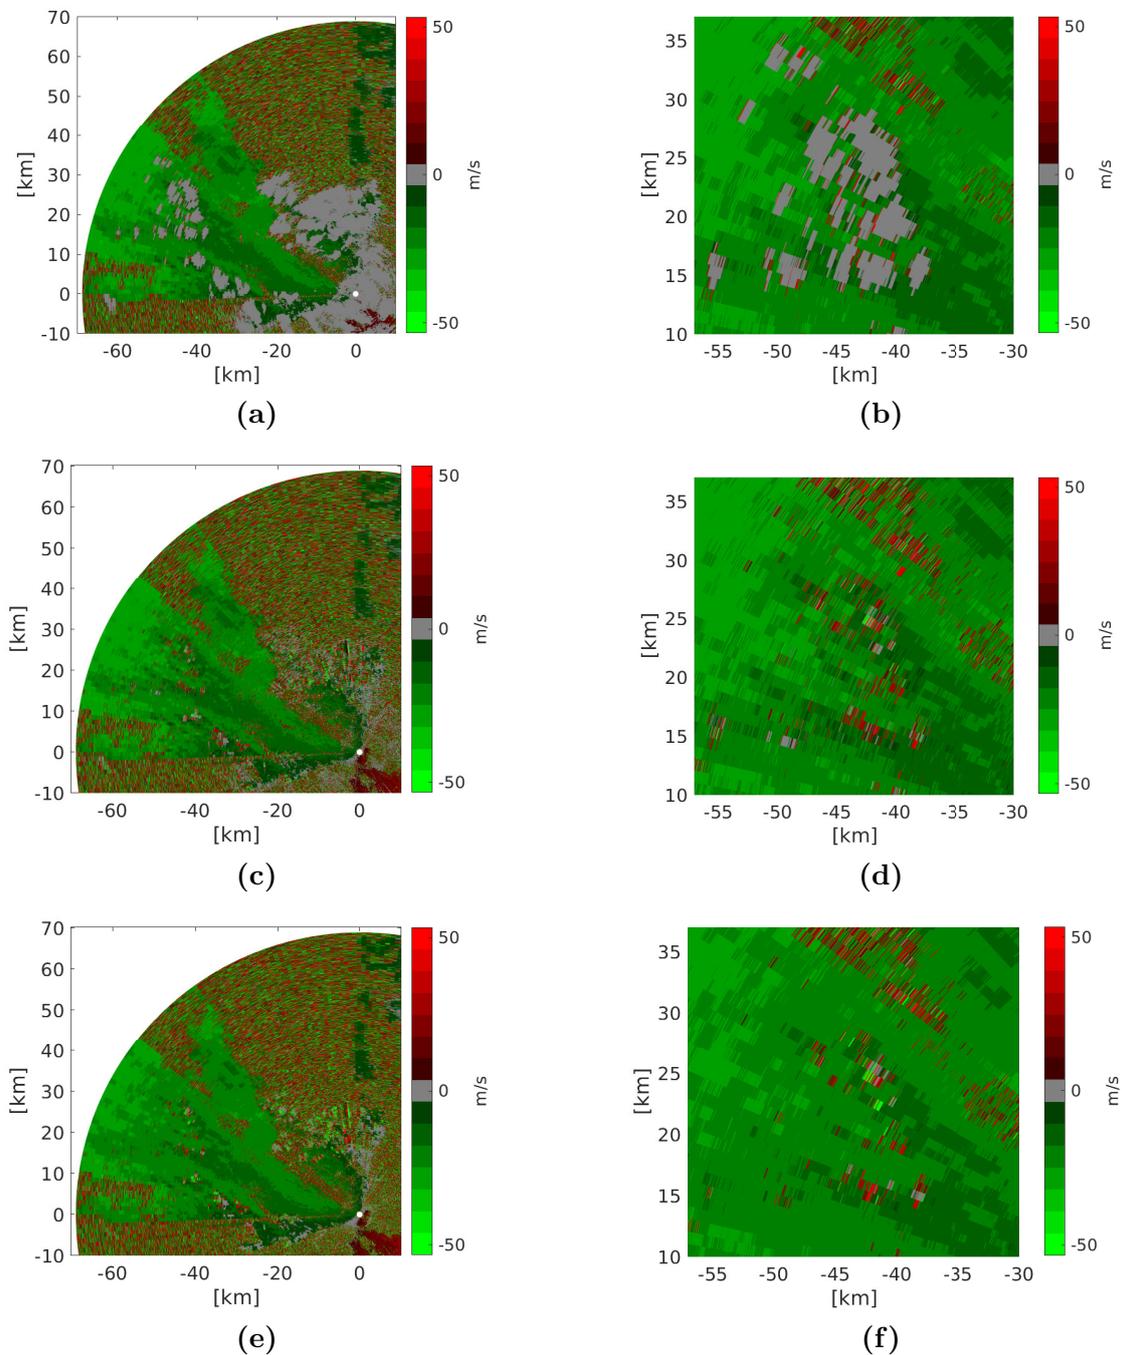


Figura 6.10: PPI de la velocidad Doppler media. (a) Aplicando DA. (b) Aplicando DA. (c) Aplicando ASPASS. (d) Aplicando ASPASS. (e) Aplicando la CNN. (f) Aplicando la CNN.

fenómeno. Por su parte, dado el resultado observado en la Figura 6.10(e), y que el mismo es comparable con DA y ASPASS, se afirma que la CNN estima de forma correcta la velocidad Doppler media del fenómeno, tanto en las zonas que presentan clutter terrestre como en las que no poseen sus contribuciones. Mirando en detalle las Figuras 6.10(d) y 6.10(f) se concluye que la CNN presenta valores más homogéneos que ASPASS en las regiones con clutter y sin clutter, lo cual se justifica a partir de que la CNN posee menores errores relativos que ASPASS en la estimación de velocidad como se mostró en la Sección 6.4

Las Figuras 6.11(a), 6.11(c), 6.11(e) muestran los PPIs del ancho espectral después de aplicar SPPP, ASPASS y la CNN, respectivamente, mientras que en las Figuras 6.11(b), 6.11(d), 6.11(f) se muestra nuevamente la ampliación aplicada a la reflectividad. De la Figura 6.11(a) se aprecia que en las zonas identificadas como clutter, los estimados obtenidos con SPPP poseen valores bajos, como es de esperar para este tipo de contribuciones [3]. Además se observa que en las zonas de fenómeno, los valores de σ_p se encuentran entre 1 m/s y 6 m/s, correspondiéndose los valores más altos a zonas de baja SNR. De la Figura 6.11(c), se advierte como ASPASS elimina las zonas de clutter y estima el ancho espectral obteniéndose valores altos, los cuales se corresponden con los del ruido. Por su parte, de la Figura 6.11(e) se observa que en las zonas de clutter la CNN presenta un comportamiento similar al de ASPASS. Además, para las zonas de fenómeno y ruido sus valores son comparables a los de SPPP y ASPASS. Es importante mencionar que en las zonas de clutter intenso la SNR es muy baja, lo cual hace que tanto ASPASS como la CNN estimen valores sesgados.

Con el presente estudio empleando mediciones de radar, se valida que la CNN entrenada con datos sintéticos es capaz de realizar estimaciones comparables con las de los algoritmos SPPP y ASPASS. Se concluye que la CNN cumple satisfactoriamente el propósito con el que fue desarrollada. Como se mencionó en la Sección 5.5 el éxito en el método propuesto radica en que los datos sintéticos generados usando modelos gaussianos tanto para las distribuciones de probabilidad como para las DEPs del clutter y del fenómeno meteorológico constituyen una buena representación de los datos meteorológicos.

6.6. Conclusiones

En este capítulo se extendió el método presentado en el Capítulo 5 para señales obtenidas al emplear el modo de operación *staggered 2/3*. El algoritmo utiliza una red neuronal convolucional como solución a la estimación de momentos espectrales del fenómeno meteorológico. Al igual que para el modo convencional, se usan datos sintéticos para entrenar la red. Esto último está sustentado en el hecho de que el modelo matemático usado para generar los datos sintéticos se ajusta satisfactoriamente

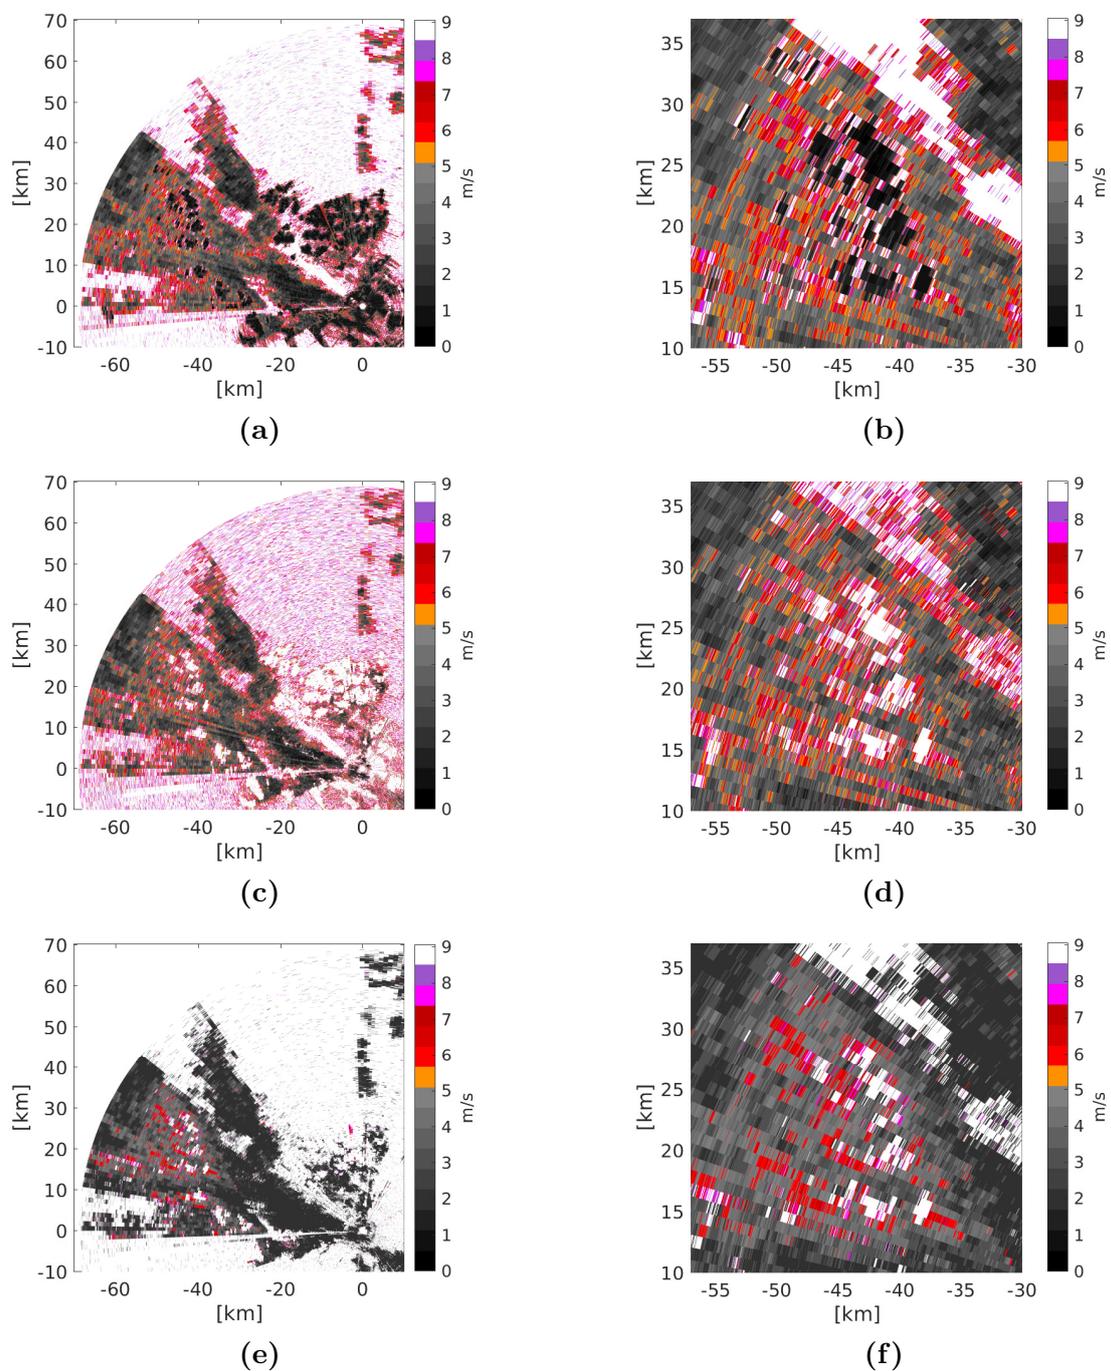


Figura 6.11: PPI del ancho espectral. (a) Aplicando SPPP. (b) Aplicando SPPP. (c) Aplicando ASPASS. (d) Aplicando ASPASS. (e) Aplicando la CNN. (f) Aplicando la CNN.

a las mediciones de los radares meteorológicos. Además, esta estrategia para entrenar la red permite generar grandes bases de datos, abarcando de esta forma, la mayoría de las configuraciones meteorológicas posibles. Asimismo, una de las ventajas de la metodología presentada es que la CNN posee la capacidad de realizar una clasificación implícita para detectar clutter terrestre, para de esta forma poder procesar escenarios en los que el mismo está presente, como en los que no lo está, evitando la necesidad de contar con una etapa previa para su identificación.

Se propuso un diseño de CNN con tres ramas, donde cada rama estima uno de los siguientes parámetros: CSR , v_p y σ_p , respectivamente. Una vez formulado el problema a resolver, se presentó el método y la generación de los datos de entrenamiento y validación. Posteriormente, se realizó un estudio de 12 redes convolucionales de una dimensión, variando el número y tamaño de los núcleos en las capas convolucionales, como la cantidad de estas últimas, también se varió el número de capas densas y de neuronas por capa. Para el estudio se usaron las métricas accuracy, loss y tiempo de predicción. Del mismo, se seleccionó la red de mayor desempeño usando los datos de validación.

En la etapa de validación de la red elegida, además de la métrica accuracy, se evaluaron los errores de índices en la diferencia entre las clases que predice la CNN y las verdaderas. De esta forma se corroboró que para las tres ramas, el error en la predicción posee forma de campana gaussiana, angosta, centrada en cero, lo que da cuenta de errores insesgados y con una baja dispersión.

Una vez entrenada la red, se procedió a evaluar el desempeño de la misma en la estimación de los momentos espectrales. Para ello, el estudio se dividió en dos etapas: en la primera, se emplean simulaciones de tipo Monte Carlo con datos sintéticos, y en la segunda se utilizan mediciones adquiridas con el radar RMA-12. A su vez, la primera etapa se divide en dos escenarios: el primero contempla únicamente la presencia de fenómeno y ruido, y el segundo contempla la presencia de clutter contaminando la señal. Para ambos escenarios se llevan a cabo diferentes experimentos, en los cuales se toman el sesgo y la desviación estándar de las estimaciones como métricas. Además, con fines comparativos también se evaluó el desempeño de otros métodos de acuerdo a la circunstancia. Para el primer escenario, se consideró DA en la estimación de velocidad Doppler media y SPPP en la estimación del ancho espectral, mientras que en el segundo escenario se trabajó con ASPASS.

Los resultados obtenidos en general son prometedores, siendo para el primer escenario las estimaciones de la CNN mejores que las de DA y las de SPPP en el rango de parámetros estudiados. Para el segundo escenario, por un lado se obtuvo mejor desempeño en la CNN que en ASPASS para la estimación de la velocidad Doppler media y el ancho espectral, no así para la estimación de potencia. Por otro lado, se concluyó que la CNN entrenada usando un ancho espectral de clutter teórico σ_{t_1} puede ser aplicada

a señales que posean otro valor σ_{t_2} , siempre y cuando estos valores no difieran significativamente. La tolerancia de este resultado dependerá de las características del radar y de los parámetros de las mediciones.

Por último, se validó el desempeño de la CNN utilizando mediciones reales de radar meteorológico adquiridas con el radar argentino RMA-12 ubicado en el aeropuerto de la ciudad de San Carlos de Bariloche. En general, se observaron buenos resultados, comparables con los obtenidos usando SPPP, DA y ASPASS. Para la velocidad Doppler media se observó mayor homogeneidad en los resultados con la CNN que con ASPASS. Se verificó la capacidad del método propuesto de funcionar correctamente tanto en ausencia como en presencia de clutter terrestre. La CNN una vez entrenada, posee una carga computacional moderada y presenta la ventaja de procesar todos los datos en bloques (varios CPIs y todos los radiales), haciendo al método un buen candidato para implementaciones en tiempo real.

Al igual a lo mencionado en la Sección 5.6 la red puede ser entrenada usando señales generadas sintéticamente con diferentes modelos matemáticos. Esto permite contemplar situaciones observadas en mediciones reales, en las cuales la señal meteorológica no sigue un modelo gaussiano para la DEP del fenómeno [7].

Cabe señalar que la metodología introducida en el Capítulo 5 para el modo convencional y extendida en el presente para el modo *staggered* posee el espíritu de mostrar la posibilidad de usar modelos de machine learning, en particular redes neuronales, entrenados con datos sintéticos para resolver el problema de estimación de momentos espectrales, y no la de encontrar la estructura de red neuronal óptima. Esto último sería muy costoso, computacionalmente hablando dado el gran número de hiperparámetros existentes. Otro punto importante a tener en cuenta, es el grillado a la hora de generar los datos sintéticos. Como trabajo futuro, dada una red neuronal, es interesante estudiar su impacto en el desempeño en la estimación, inclusive dependiendo de las características de la señal a procesar, se pueden elegir grillados específicos para esa aplicación.

Capítulo 7

Clasificación de la composición de la señal utilizando Redes Neuronales

“En algún lugar algo increíble está esperando ser descubierto.”

— CARL SAGAN

7.1. Introducción

Varios de los algoritmos de filtrado de clutter terrestre estudiados a lo largo de esta tesis (GMAP, GMAP-TD, ASPASS) requieren de una etapa previa para detectar la presencia de clutter y determinar si es necesario aplicar dicho filtro. De no contar con la etapa de identificación de clutter, en aquellas situaciones donde la señal meteorológica no se encuentre contaminada con clutter, el filtro aplicado inevitablemente afectará la estimación de los momentos espectrales del fenómeno, siendo este efecto más significativo en la medida que el fenómeno meteorológico posea velocidad Doppler cercana a cero, como consecuencia de que se filtrará parte del mismo. Si bien estos algoritmos adaptivos reconstruyen esas componentes del espectro del fenómeno que son eliminadas, dicha reconstrucción posee error y el resultado final de la estimación de los momentos espectrales se ve degradado, lo cual es admisible frente a la presencia de clutter, pero carece de sentido ante el filtrado innecesario en su ausencia. Por este motivo, la clasificación de la composición de la señal meteorológica, en particular la detección de clutter terrestre, es necesaria.

En este capítulo, se introduce un método de clasificación de la señal meteorológica utilizando redes neuronales convolucionales (CNNs). Se proponen cuatro posibles diferentes composiciones de señal de radar meteorológico: *clutter + ruido*, *clutter + fenómeno + ruido*, *fenómeno + ruido*, y *ruido*. El método se aplica para el modo con-

vencional de operación del radar con PRI uniforme y para el modo staggered 2/3. Para cada uno de ellos se realiza un estudio de diferentes CNNs con el objetivo de seleccionar la de mejor desempeño sobre los datos de validación. El entrenamiento se lleva a cabo mediante datos sintéticos IQ de radar meteorológico para un único canal de recepción, abarcando un gran número de configuraciones meteorológicas posibles. Para ambos modos de operación del radar, se estudia el desempeño de la CNN seleccionada una vez entrenada, mediante diferentes experimentos, en los cuales se recrean situaciones de interés, variando alguna de las magnitudes meteorológicas y fijando el resto. También, para ambos modos se estudia el desempeño de la CNN sobre datos reales adquiridos con radares meteorológicos argentinos de la serie RMA.

El capítulo está organizado de la siguiente manera. En la Sección 7.2 se formula el problema de clasificación a resolver, se describe el método de resolución y se generan los datos de entrenamiento y validación. En la Sección 7.3 se desarrolla el método para el modo convencional de operación del radar. En la misma, se realiza un estudio de CNNs de diferentes tamaños y se elige la de mejor desempeño. Posteriormente, mediante simulaciones numéricas y 8 experimentos diferentes se evalúa el desempeño de la red elegida. Asimismo, se utilizan datos reales de los radares RMA-12 y RMA-11 para validar la clasificación de la CNN. Por su parte en la Sección 7.4 se desarrolla el método para el modo de operación *staggered*. Análogamente que para PRI uniforme, se realiza un estudio de diferentes CNNs y se elige la de mejor desempeño. Posteriormente, se evalúa el desempeño de la CNN mediante simulaciones numéricas y 10 experimentos diferentes. Por último, se procesan datos reales adquiridos con el radar RMA-12 y se analiza cualitativamente el desempeño de la CNN. Finalmente, en la sección 7.5 se presentan conclusiones.

7.2. Formulación del problema

Siguiendo un razonamiento similar al presentado en el Capítulo 5 en cuanto al uso de la DEP de la señal meteorológica para realizar estimaciones de sus momentos espectrales, en esta sección se propone el empleo de una NN con el objetivo de clasificar la composición de la señal radar. La clasificación se divide en cuatro categorías (o clases): *clutter + ruido*, *clutter + fenómeno + ruido*, *fenómeno + ruido*, y *ruido*. En la Figura 7.1 se muestran ejemplos de DEPs obtenidas mediante la generación de datos sintéticos. Las Figuras 7.1(a), 7.1(b), 7.1(c) y 7.1(d) se corresponden a las situaciones *clutter + fenómeno + ruido*, *clutter + fenómeno + ruido*, *fenómeno + ruido* y *ruido*, respectivamente. En la Tabla 7.1 se encuentran los parámetros generales de las simulaciones con los que fueron generados los espectros mostrados, y la descripción de cada subfigura presenta información específica de los parámetros particulares para cada situación.

Parámetro	Símbolo	Valor
Frecuencia de portadora	F_c [GHz]	5,6
Longitud de onda	λ [cm]	5,35
Nro. de muestras (pulsos)	M	64
PRI	T_u [ms]	0,4
Velocidad máxima no ambigua	v_a [m/s]	33.5
Ancho teórico del clutter	σ_t [m/s]	0.27
Potencia del fenómeno	p_p [u.a]	1

Tabla 7.1: Parámetros para la simulación.

Cabe destacar que, para los parámetros elegidos, las cuatro situaciones mostradas son fáciles de clasificar para el ser humano mediante la simple inspección de la DEP. No ocurre lo mismo en las fronteras que separa una clase de otra, en las cuales la complejidad del problema aumenta. Para sustentar esto último, en la Figura 7.2 se muestra la misma composición de señal (*clutter + fenómeno + ruido*), siendo la diferencia entre las Figuras 7.2(a) y 7.2(b) el valor de σ_p . De las mismas se aprecia que al aumentar el ancho espectral del fenómeno se vuelve más dificultoso distinguir la presencia de clutter, debido a que se confunde la clasificación con la clase *fenómeno + ruido*.

Además de lo mencionado en la Sección 5.2 respecto de la eficacia y eficiencia de la NNs para resolver este tipo de problemas, se suma la capacidad que ellas poseen de aprender estructuras ocultas en los datos, las cuales muchas veces pasan desapercibidas para el ser humano, logrando de esta forma realizar clasificaciones de forma correcta. Por otro lado, es importante advertir que las NNs también, con cierta probabilidad, van a incurrir en equivocaciones en aquellas situaciones donde no sean distinguibles las distintas contribuciones a la DEP estimada. Sin embargo, con el método propuesto en esta tesis, se las podrán entrenar con una gran cantidad de escenarios de este tipo, con el propósito de disminuir esa probabilidad de error.

7.2.1. Método

Se toma como entrada a la NN la DEP normalizada y expresada en escala logarítmica de la señal recibida por el radar para un CPI y un rango determinado. Para estimar la DEP se aplica ventana de Kaiser con $\alpha = 8$ con el objetivo de atenuar los lóbulos secundarios del clutter cuando sus contribuciones se encuentren presentes en la señal. La salida de la NN está constituida por cuatro neuronas, representando cada una las diferentes composiciones de la señal meteorológica. Se adopta una estructura de red convolucional (CNN) para resolver el problema de clasificación. El número de capas ocultas y de neuronas por capas se estudian en la próxima sección.

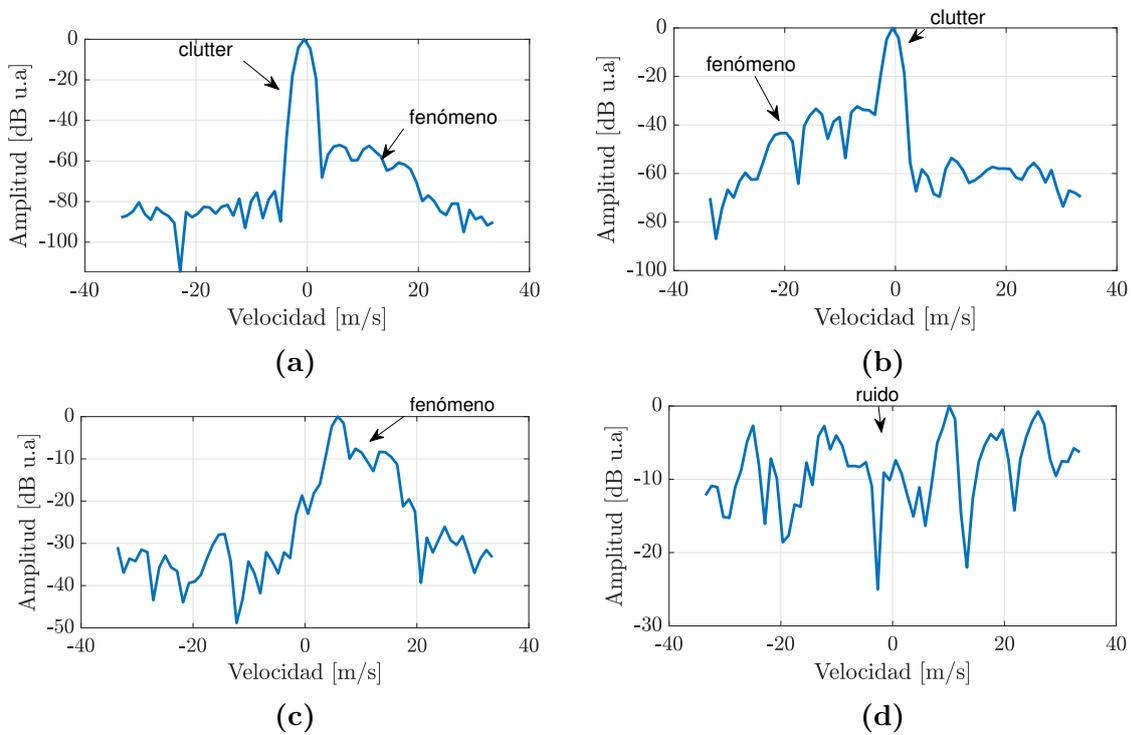


Figura 7.1: Ejemplo de DEPs de diferentes composiciones de señal. (a) $CSR = 40$ dB, $v_p = 0,3v_a = 10$ m/s, $\sigma_p = 3,34$ m/s, $SNR = 20$ dB. (b) $CSR = 20$ dB, $v_p = -0,3v_a = -10$ m/s, $\sigma_p = 3,34$ m/s, $SNR = 20$ dB. (c) $CSR \rightarrow -\infty$ dB, $v_p = 0,3v_a = 10$ m/s, $\sigma_p = 3,34$ m/s, $SNR = 20$ dB. (d) $CSR \rightarrow -\infty$ dB, $SNR \rightarrow -\infty$ dB.

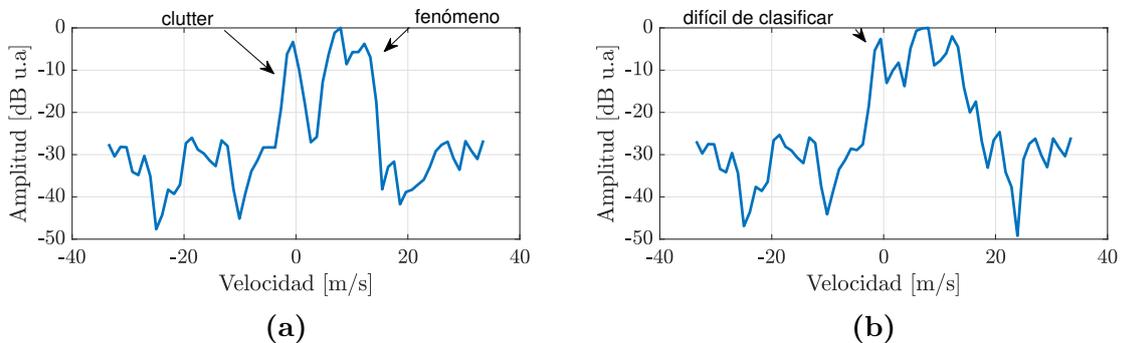


Figura 7.2: Ejemplo de DEPs en la frontera entre dos clases. (a) $CSR = 0$ dB, $v_p = 0,3v_a = 10$ m/s, $\sigma_p = 1,67$ m/s, $SNR = 20$ dB. (b) $CSR = 0$ dB, $v_p = 0,3v_a = 10$ m/s, $\sigma_p = 3,34$ m/s, $SNR = 20$ dB.

Una vez entrenada la red, el algoritmo posee dos pasos: el primero es la estimación de la DEP a partir de los datos IQ, lo cual se realiza utilizando periodograma; el segundo consiste en alimentar la CNN con la DEP estimada previamente, y de esta forma obtener la clasificación. Es importante destacar que la red neuronal puede procesar una DEP o miles de DEPs al mismo tiempo, haciendo del método muy atractivo para implementaciones en tiempo real o para procesar grandes conjuntos de datos.

7.2.2. Datos de entrenamiento y validación

Debido a la dificultad de recolectar datos reales bien etiquetados, para diferentes configuraciones meteorológicas, y teniendo en cuenta los resultados alentadores obtenidos en los Capítulos 5 y 6 para el filtrado de clutter y estimación de momentos espectrales, entonces, nuevamente se propone utilizar datos sintéticos para entrenar y validar la red. Este procedimiento se sustenta en el hecho de que el modelo matemático para la generación de la señal se ajusta bien a las mediciones de los radares meteorológicos [7]. Una de las ventajas de esta metodología consiste en que se puede recrear muchos escenarios variando los diferentes parámetros del modelo de datos para el clutter, el fenómeno y el ruido [3]. Además, permite utilizar varias realizaciones para una misma condición meteorológica. Esto último es importante, ya que la DEP obtenida a partir de los datos IQ presenta incertidumbre debido a su naturaleza aleatoria. Entonces, considerando un rango amplio de variación de los parámetros meteorológicos, de forma de sintetizar la mayor parte de las situaciones de interés, se obtienen los conjuntos de datos de entrenamiento y validación.

Para la clase *clutter + ruido* (C + N), se varía la relación entre la potencia del clutter y la potencia del ruido (CNR), desde 0 dB hasta 50 dB en una grilla uniforme de 10 valores. Para cada valor de CNR se generan 7200 realizaciones de datos IQ, obteniéndose en total 72000 DEPs.

Para la clase *clutter + fenómeno + ruido* (C + S + N), se varían cuatro parámetros (CSR, v_p, σ_p, SNR) formando una grilla tetradimensional. La CSR se toma uniformemente espaciada con 10 valores, en el rango de 0 dB hasta 50 dB. La grilla en v_p se adopta de forma uniforme en todo el intervalo Doppler ($-v_a$ hasta v_a) utilizando 30 valores, donde v_a es la velocidad máxima no ambigua. Por su parte, para la grilla de σ_p se toman 12 valores uniformemente espaciados en el intervalo $0,04v_a$ hasta $0,4v_a$. Por último, para la grilla de SNR se toman 10 valores uniformemente espaciados desde 0 dB hasta 30 dB. Con esta división de la grilla tetradimensional, se obtienen 36000 configuraciones meteorológicas diferentes. Para cada situación, se generan 2 realizaciones de datos IQ, obteniéndose en total 72000 DEPs.

Para la clase *fenómeno + ruido* (S + N), se varían tres parámetros (v_p, σ_p, SNR). La elección de los parámetros es la misma que para el caso anterior, pero con la particu-

laridad de que $CSR \rightarrow -\infty$. En total se obtienen 3600 configuraciones meteorológicas. Para cada situación, se generan 20 realizaciones de datos IQ, obteniéndose 72000 DEPs. Finalmente, para la clase de *ruido* (N), se generan 72000 realizaciones de datos IQ, obteniéndose también 72000 DEPs.

El conjunto de datos presenta en total 288000 DEPs, de las cuales aleatoriamente se selecciona el 80 % para entrenar y el restante 20 % para validar el entrenamiento. Es importante mencionar que la selección del grillado de los diferentes parámetros en cada composición de señal, se realiza basado en el conocimiento tratando con señales meteorológicas. La elección de estos grillados presenta un fuerte impacto en el desempeño de la CNN como se verá en la Sección 7.3.3, afectando en mayor medida aquellas situaciones en las que a partir de la DEP no son distinguibles las contribuciones del fenómeno meteorológico, del clutter o del ruido.

7.3. Modo convencional de operación del radar

Tanto el método propuesto en este capítulo, como el grillado de los datos de entrenamiento son similares para el modo convencional de operación del radar y el modo *staggered*. No ocurre lo mismo con la forma matemática que presenta la DEP en ambos modos de operación, haciendo que el problema a resolver presente diferentes grados de dificultad para cada caso. Por este motivo, a continuación se analiza el uso de una CNN para la clasificación de la composición de la señal radar meteorológico, tanto con datos simulados como con mediciones reales obtenidas por radares meteorológicos argentinos. Por su parte, en la Sección 7.4 se realiza un estudio similar aplicado al modo de operación *staggered*.

7.3.1. Estudio de diferentes CNNs

Si bien el objetivo no es realizar una búsqueda exhaustiva de la CNN óptima que produzca el mejor desempeño al momento de clasificar la señal de radar, es importante analizar qué impacto presenta la arquitectura de la NN sobre la clasificación de las señales y optar por una que presente un desempeño aceptable, teniendo en cuenta los tiempos de ejecución. Por este motivo, se propone estudiar 8 arquitecturas diferentes de NN, cuyas capas ocultas y número de parámetros a entrenar para cada arquitectura se presentan en la Tabla 7.2.

En las capas convolucionales de una dimensión (conv1d) la notación x, y se refiere a “ x núcleos de longitud y ”. Para las capas densas el número representado se refiere a la cantidad de neuronas en esa capa. Cada arquitectura es entrenada y validada utilizando datos sintéticos de acuerdo con la descripción presentada en la Sección 7.2.2. Las dos primeras arquitecturas no son redes convolucionales, pero se incluyeron para

Arquitectura	conv1d	conv1d	conv1d	densa	densa	densa	densa	número de parámetros a entrenar
1				50				3454
2				50	40			5454
3	10, 10			50	40			29864
4	5, 5	5, 5		50	40			16414
5	10, 10	10, 10		50	40			26374
6	5, 5	5, 5		50	40	40		18054
7	10, 10	10, 10		50	40	40		28014
8	10, 10	10, 10	10, 10	100	80	60	40	54774

Tabla 7.2: Diferentes arquitecturas de CNN estudiadas. Modo convencional.

completar el estudio, ya que permite observar como mejora el desempeño a medida que se combinan capas convolucionales y capas densas. Para este estudio en particular se toman DEPs con longitud igual a $M = 64$ muestras, lo cual coincide con el número de neuronas de la capa de entrada.

El entrenamiento de las CNN se realiza mediante la librería Tensorflow 2.2.0 [87] y el API Keras [88]. Como función de costo (en inglés, loss) y optimizador se utilizaron *Categorical cross-entropy* y Adam, respectivamente. Se seleccionó un learning rate de 10^{-4} , y un batch size de 512. Para la activación de cada capa oculta se eligió la función *Relu*, y para la capa de salida la función *softmax*. Además, se adoptó la regularización *Early-Stopping* monitoreando el accuracy de validación, con el propósito de evitar el sobreajuste. Como métricas para el estudio se seleccionaron la función de loss, el accuracy y el tiempo de predicción, aplicadas a los datos de validación. El entrenamiento de las redes neuronales se realiza en una PC con Intel core i7 (3.4 GHz), 32 GB de memoria RAM y una tarjeta gráfica Nvidia 750 Ti con 2 GB de memoria RAM.

En la Figura 7.3 se observa el resultado de las tres métricas adoptadas en el estudio para las 8 arquitecturas. La Figura 7.3(a) muestra la función de loss. De la misma se observa que los valores disminuyen a medida que se aumenta el número de capas ocultas, siendo las arquitecturas número 6 y 8 las que menores valores presentan. En la Figura 7.3(b) se presenta el accuracy. Para todas las arquitecturas esta métrica presenta un valor aceptable, debido a que en todos los casos se encuentra por encima de 0,91. Asimismo, el accuracy aumenta a medida que se combinan las capas convolucionales y las densas. Nuevamente, las arquitecturas 6 y 8 son las que presentan mejor desempeño. Por su parte, la Figura 7.3(c) muestra los tiempos promedios de predicción. Para calcular valores promedios se tomaron 10 repeticiones para cada arquitectura. El tiempo se incrementa con el número de capas ocultas en la red, siendo la arquitectura número 8 casi 2 veces más lenta que la arquitectura número 1. Las arquitecturas 6 y 8 presentan valores prácticamente iguales para las dos métricas anteriores, sin embargo la 8 requiere en promedio 1.22 veces del tiempo de la arquitectura número 6 para procesar el mismo volumen de datos.

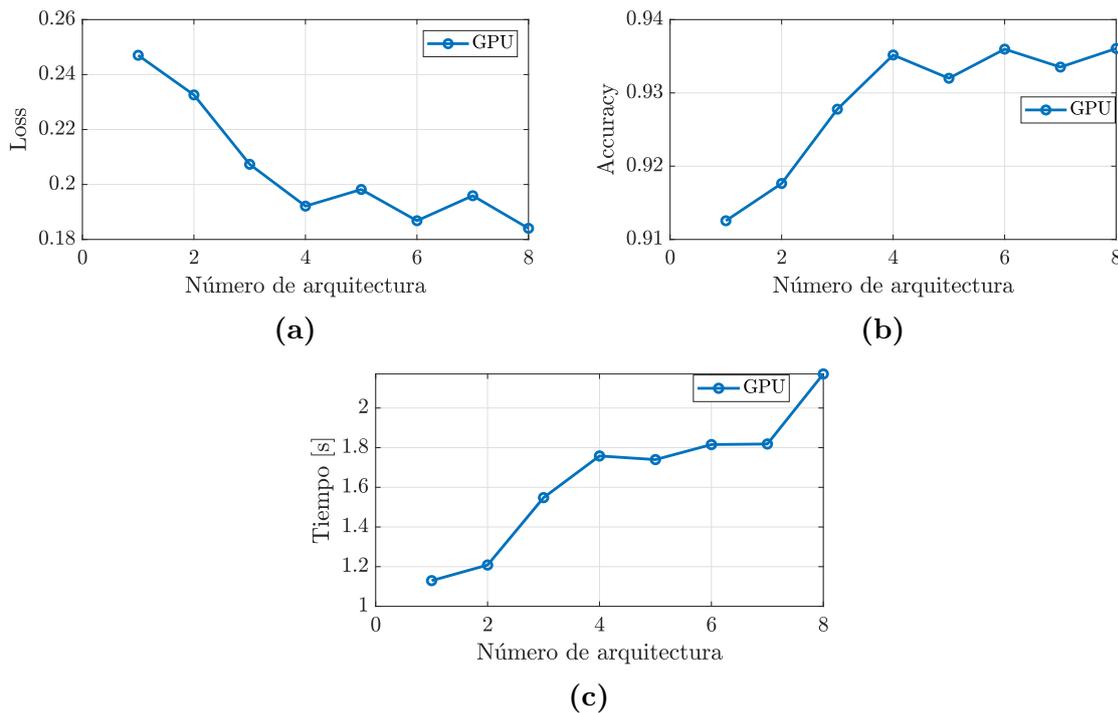


Figura 7.3: Métricas del estudio de las diferentes arquitecturas de CNN. (a) Loss. (b) Accuracy. (c) Tiempo de predicción promedio.

En aplicaciones en tiempo real, se procesan grandes volúmenes de datos entre barridos, lo que implica un uso eficiente de los recursos para reducir el costo computacional, manteniendo buen desempeño en la clasificación. Por lo tanto, para lograr un balance entre costo computacional y desempeño en la clasificación, basados en los resultados obtenidos, se propone utilizar la CNN número 6. Cabe mencionar que los tiempos obtenidos en el estudio anterior dependen de la tarjeta gráfica que se use, es decir que un hardware diferente permitiría reducir los tiempos ajustándolos a los requerimientos de sistemas reales de procesamiento en aplicaciones de radar meteorológico.

7.3.2. Entrenamiento y validación de la CNN

Con el objetivo de profundizar en el entrenamiento de la CNN elegida, las Figuras 7.4(a) y 7.4(b) muestran el loss y el accuracy para los datos de entrenamiento y validación en función del número de épocas, respectivamente. De las mismas se observa que, la función de loss disminuye y el accuracy aumenta, para ambos conjuntos de datos. Esta observación indica que la CNN aprendió a clasificar las diferentes composiciones en las que se encuentra la señal de radar meteorológico. Por su parte, la Figura 7.5 muestra la matriz de confusión utilizando los datos de validación. De la misma se aprecia que para cada clase se obtiene una tasa de acierto de más del 90%. Además, se observan las cantidades porcentuales de falsos positivos (FP) y de falsos negativos (FN). Estos valores están asociados a errores en la clasificación, y se deben, principal-

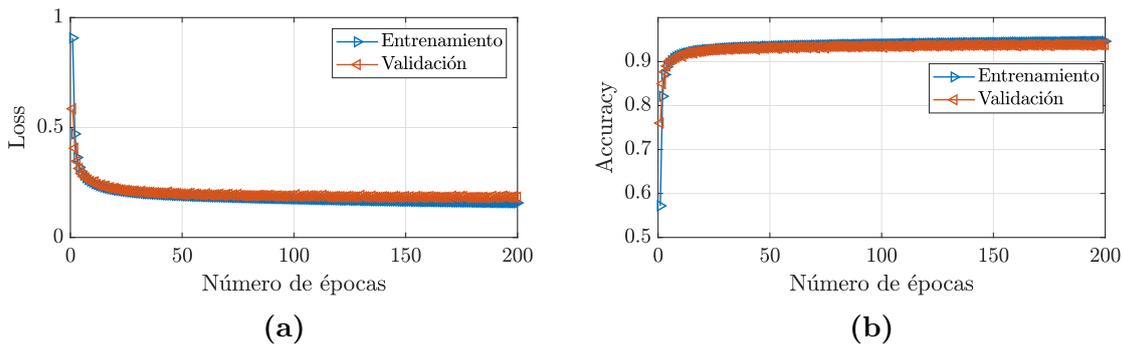


Figura 7.4: Desempeño del entrenamiento y la validación en el modo convencional. (a) Loss. (b) Accuracy.

Clases verdaderas	C + N	13927	270	235	9	96.4%	3.6%
	C + S + N	1101	13042	22	265	90.4%	9.6%
	N	54	3	14108	233	98.0%	2.0%
	S + N	37	159	761	13373	93.3%	6.7%
		92.1%	96.8%	93.3%	96.3%		
		7.9%	3.2%	6.7%	3.7%		
		C + N	C + S + N	N	S + N		
		Clases predichas					

Figura 7.5: Matriz de confusión de la CNN entrenada utilizando los datos de validación.

mente, a situaciones que se encuentran cerca de la frontera entre dos o más clases, por ejemplo: bajos valores de SNR, altos y bajos valores de σ_p , entre otros.

Diferentes tamaños de la capa de entrada

Como se indicó cuando se presentó el método al comienzo del capítulo, el número de neuronas de la capa de entrada de la CNN coincide con la longitud de la DEP, que a su vez, es igual al número de muestras, M , o de pulsos en un CPI. En esta sección se estudia el desempeño de la arquitectura número 6 para diferentes tamaño de la capa de entrada. Se eligen los valores $M = 16, 32, 64, 128$, los cuales son representativos de escenarios reales de radar meteorológico. Para cada valor de M se entrena la red neuronal con datos sintéticos utilizando el mismo grillado y número de realizaciones presentado en la Sección 7.2.2 para los conjuntos de entrenamiento y validación. Se elige el accuracy como métrica con el propósito de comparar el desempeño de las cuatro

redes entrenadas. En la Figura 7.6 se observa el valor de esta métrica para los datos de validación en función del número de neuronas de la capa de entrada. De la misma se observa que el desempeño de la CNN aumenta con el número de muestras en la DEP. Este es un resultado esperado, dado que mientras mayor es el número de muestras de la señal IQ, menor es el sesgo en la estimación de la DEP utilizando periodograma [3] debido a la ventana.

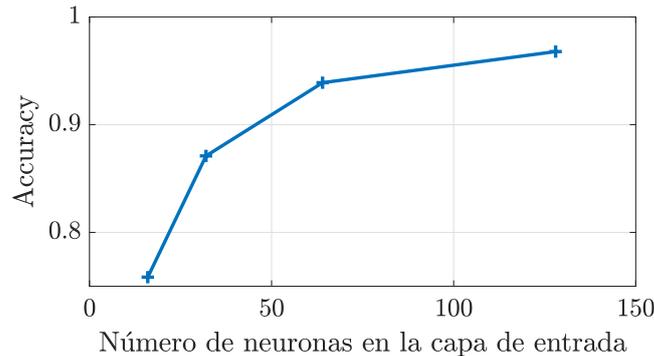


Figura 7.6: Accuracy de la arquitectura número 6 en función del número de neuronas de la capa de entrada.

7.3.3. Experiencia con datos sintéticos

De la matriz de confusión, presentada en la Sección 7.3.2, se observa que existe cierta probabilidad de clasificar erróneamente, asociada a situaciones en las cuales a partir de la DEP se dificulta diferenciar las contribuciones de cada una de las posibles componentes de la señal. Por este motivo, a continuación se profundiza el estudio del desempeño de la CNN para $M = 64$, en configuraciones meteorológicas de interés. Con tal fin, se realizan 8 experimentos: para los 4 primeros se simulan escenarios en los que solo existe *fenómeno + ruido* ($S + N$); para los restantes 4 experimentos se simulan escenarios en los que existe *clutter + fenómeno + ruido* ($C + S + N$). Dada la alta dimensionalidad del problema, en todos los experimentos se simulan datos IQ fijando los valores de los parámetros del clutter y del fenómeno, según corresponda, y se varía la SNR de 0 dB a 30 dB. Además, en todos los experimentos para cada valor de SNR se utilizan 1000 realizaciones. Los parámetros generales de las simulaciones se presentan en la Tabla 7.1.

Para los primeros 4 experimentos, dado que solo existe fenómeno y ruido, se fijan los valores de v_p y σ_p . En el primero $v_p = 0$ m/s y $\sigma_p = 0,1v_a$, en el segundo $v_p = 0,4v_a$ m/s y $\sigma_p = 0,1v_a$, en el el tercero $v_p = 0$ m/s y $\sigma_p = 0,05v_a$, y en el cuarto $v_p = 0,4v_a$ m/s y $\sigma_p = 0,05v_a$.

La Figura 7.7 muestra los resultados de las clasificaciones de los primeros cuatro experimentos. La primera observación que cabe hacer sobre dichos resultados, está relacionada con el comportamiento para valores bajos de SNR (< 5 dB). En esa situación,

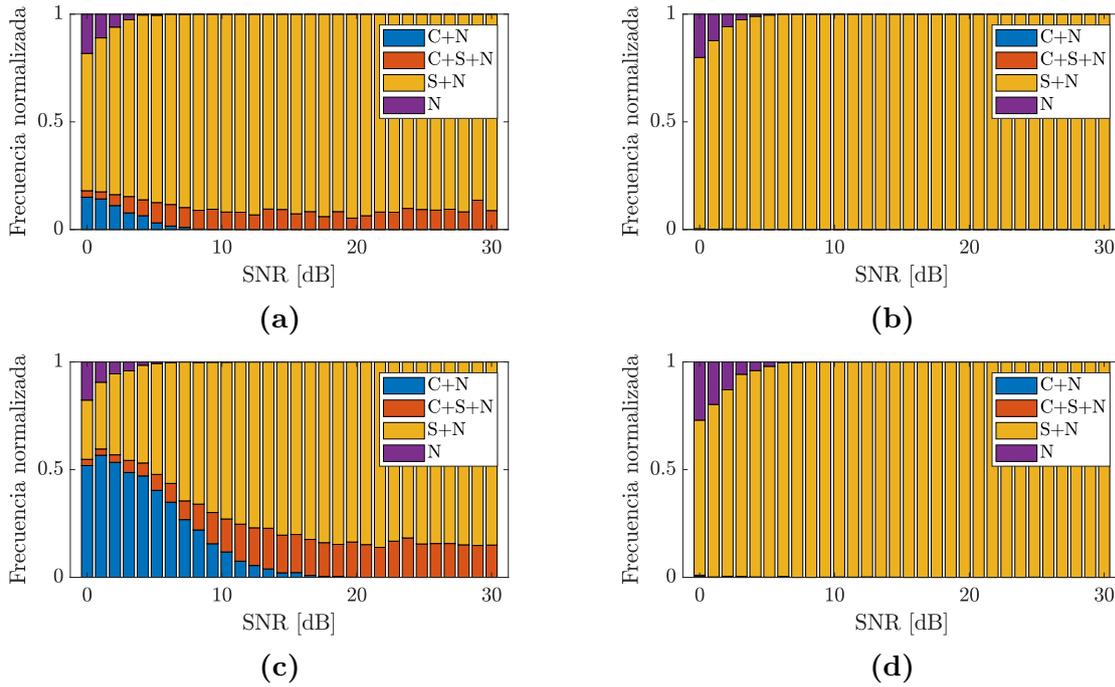


Figura 7.7: Análisis de error en la clasificación de la clase S + N para el modo convencional. (a) Primer experimento, $v_p = 0$ m/s y $\sigma_p = 0,1v_a$. (b) Segundo experimento, $v_p = 0,4v_a$ m/s y $\sigma_p = 0,1v_a$. (c) Tercer experimento, $v_p = 0$ m/s y $\sigma_p = 0,05v_a$. (d) Cuarto experimento, $v_p = 0,4v_a$ m/s y $\sigma_p = 0,05v_a$.

en todos los experimentos se observa que la DNN elige la clase N erróneamente. Este resultado es esperado, debido a que para esos valores de SNR, es difícil distinguir la DEP del fenómeno inmersa en ruido intenso. La segunda observación está vinculada a las situaciones en las que $v_p = 0$ m/s. De las Figuras 7.7(a) y 7.7(c) se aprecia que la DNN se confunde con las clases C + N y C + S + N. Por un lado, la confusión con la clase C + N está asociada a valores pequeños de SNR, y este error en la clasificación aumenta significativamente cuando disminuye el valor de σ_p . Este efecto es consecuencia de que cuanto más pequeño es el ancho espectral del fenómeno meteorológico y más cercana a cero se encuentre su velocidad Doppler media, entonces más semejante será su DEP a la del clutter terrestre incrementando la probabilidad de que la CNN se equivoque al clasificarlas. Por otro lado, el error en la clasificación con la clase C + S + N ocurre en todo el intervalo de valores de SNR estudiados, y aumenta con la disminución de σ_p . Finalmente, cabe describir las características del comportamiento para valores de velocidad del fenómeno meteorológico alejadas de cero. De las Figuras 7.7(b) y 7.7(d) se aprecia que la CNN sólo se confunde con la clase N para valores de SNR < 5 dB, con una mayor tasa de error a medida que σ_p disminuye. Debido a que $v_p = 0,4v_a$, la red no confunde el espectro del fenómeno con el del clutter, obteniéndose de esta forma buenos resultados.

Para los cuatro experimentos restantes, dado que la composición de la señal simulada presenta contribuciones de clutter, fenómeno y ruido se fijan los valores de los

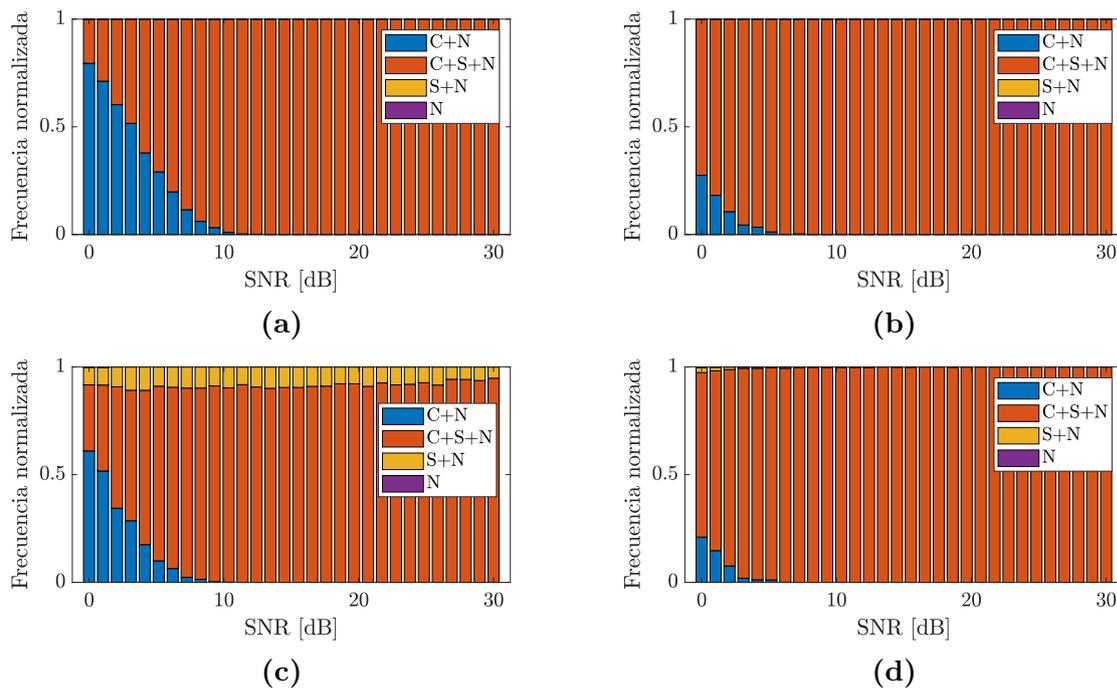


Figura 7.8: Análisis de error en la clasificación de la clase $C + S + N$ para el modo convencional. (a) Quinto experimento, $v_p = 0$ m/s, $\sigma_p = 0,1v_a$ y $CSR = 40$ dB. (b) Sexto experimento, $v_p = 0,4v_a$ m/s, $\sigma_p = 0,1v_a$ y $CSR = 40$ dB. (c) Séptimo experimento, $v_p = 0$ m/s, $\sigma_p = 0,1v_a$ y $CSR = 10$ dB. (d) Octavo experimento, $v_p = 0,4v_a$ m/s, $\sigma_p = 0,1v_a$ y $CSR = 10$ dB.

parámetros v_p , σ_p y CSR . En el quinto experimento $v_p = 0$ m/s, $\sigma_p = 0,1v_a$ y $CSR = 40$ dB, en el sexto $v_p = 0,4v_a$ m/s, $\sigma_p = 0,1v_a$ y $CSR = 40$ dB, en el séptimo $v_p = 0$ m/s, $\sigma_p = 0,1v_a$ y $CSR = 10$ dB y en el octavo $v_p = 0,4v_a$ m/s, $\sigma_p = 0,1v_a$ y $CSR = 10$ dB.

En la Figura 7.8 se presentan los resultados de las clasificaciones de la segunda tanda de experimentos. En los cuatro casos se observa que para valores bajos de SNR (< 5 dB), la CNN confunde la clase verdadera con $C + N$. Este error de clasificación es más significativo cuando la velocidad del fenómeno se encuentra próxima a cero y cuando la CSR toma valores grandes. Por otro lado, en la Figura 7.8(c) se advierte que la CNN confunde la clase verdadera con $S + N$ para todos los valores de SNR estudiados, efecto que no se manifiesta en el quinto experimento cuya única diferencia es el valor de CSR . Es decir, que este error de clasificación se manifiesta al disminuir el valor de CSR y es consecuencia de la superposición que existe entre los espectros del clutter y del fenómeno, debido a que este último posee velocidad Doppler media cero. En la Figura 7.8(a) este error de clasificación no se manifiesta a causa de que el espectro del fenómeno es enmascarado con el del clutter terrestre y se paga con un incremento en clasificar $C + N$ erróneamente. Este tipo de errores disminuyen a medida que aumenta la velocidad Doppler media y la CSR es baja, tal y como se observa en la Figura 7.8(d).

En general, se concluye que la CNN presenta buen desempeño utilizando datos sintéticos. El mismo se degrada en situaciones esperadas: valores bajos de SNR, ve-

locidad Doppler media alrededor de 0 m/s (o múltiplos de $2v_a$) y valores bajos de σ_p .

7.3.4. Procesamiento de datos reales

En esta sección se estudia el desempeño de la CNN a partir del procesamiento de datos reales adquiridos con radares argentinos de la serie RMA. Debido a que la red neuronal es entrenada utilizando datos sintéticos, el estudio llevado a cabo sobre conjuntos de datos reales tiene por objetivo analizar la capacidad de generalización de la CNN para estas situaciones. Los datos reales empleados en el análisis fueron adquiridos por los radares RMA-12 y RMA-11, este último situado en la ciudad de Termas de Río Hondo, Argentina.

RMA-12

La PRI del barrido considerado es 1 ms, lo cual equivale a una velocidad máxima no ambigua $v_a = 13,33$ m/s. Con el objetivo de observar en detalle la zona donde se concentra la mayor parte del fenómeno y del clutter, en los gráficos que se presentan a continuación se limita la región a aproximadamente $1/4$ (90°) de un barrido completo (360°).

Cabe aclarar que el conjunto de datos del RMA-12 que se analiza coincide con el utilizado en las Secciones 4.4 y 5.5, como así también las regiones que se representarán. De cualquier manera, para analizar los resultados de la clasificación en las Figuras 7.9(a) y 7.9(b) se muestran los PPI de la reflectividad y de la velocidad Doppler media, respectivamente. Las estimaciones de velocidad se obtuvieron mediante el algoritmo PPP. De forma concisa, las regiones de alta reflectividad y velocidad Doppler media próxima a cero corresponden a clutter terrestre, mientras que las zonas que corresponden al fenómeno meteorológico son aquellas que poseen reflectividad intermedia que presentan un gradiente de velocidad suave, o bien saltos abruptos de un extremo del intervalo Doppler hacia el otro, a causa del efecto de *aliasing*, como consecuencia del valor pequeño de la velocidad máxima no ambigua. En la Sección 4.4 se cuenta con un análisis detallado de la región, donde además se destacan cerros populares de Bariloche a partir de conocimiento geográfico del terreno donde se encuentra emplazado el radar.

Por otro lado, la Figura 7.9(c) muestra la clasificación de los datos empleando la CNN. En ella se observa que la red identificó la existencia de las cuatro composiciones que se definieron a partir de las clases. Por otro lado, a simple vista se observa que la clasificación que realiza la CNN coincide con el análisis previo teniendo en cuenta la reflectividad y la velocidad Doppler media. Las regiones con valores altos de reflectividad y velocidad próxima a cero han sido asignados a las clases C+N o C+S+N; las zonas en las que la reflectividad toma valores intermedios y la velocidad cambia con

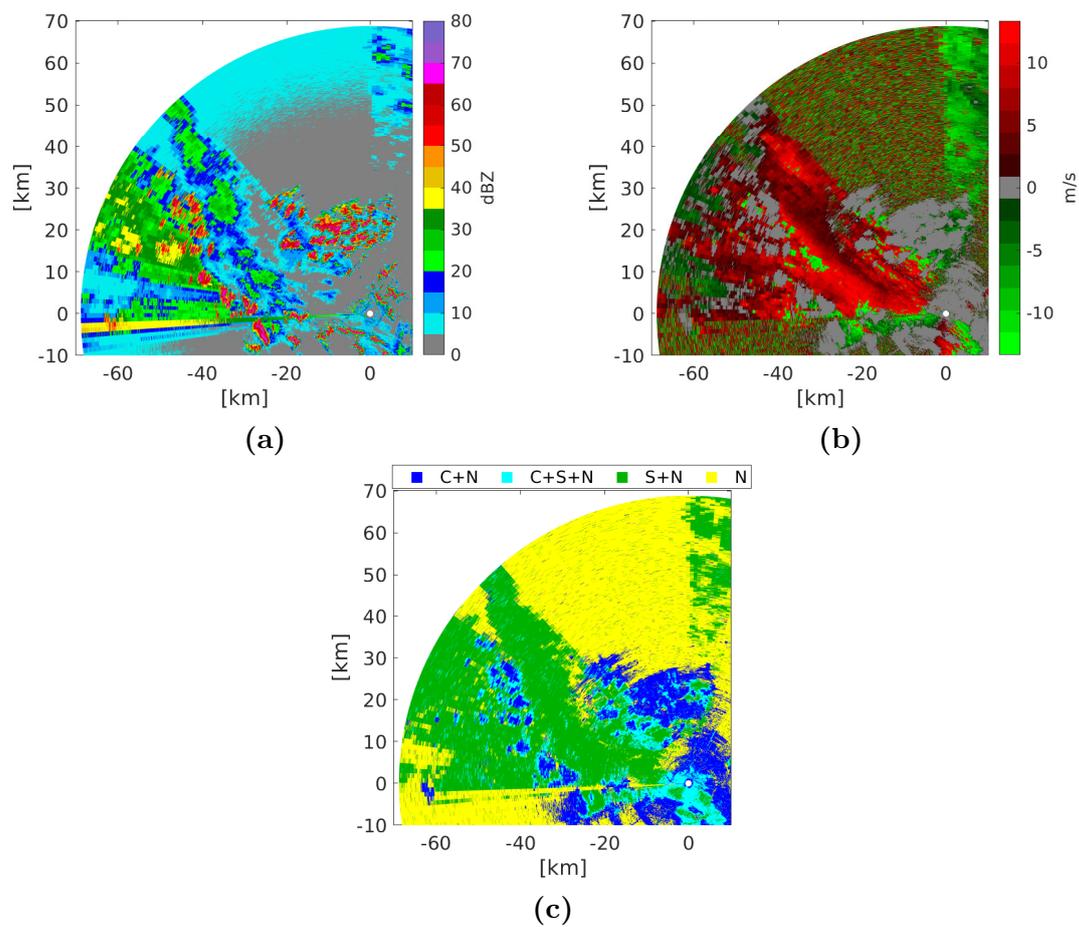


Figura 7.9: Resultados del procesamiento de los datos reales. (a) PPI de la reflectividad. (b) PPI de la velocidad Doppler media. (c) Clasificación utilizando la CNN.

un gradiente suave, con algún salto debido al aliasing, han sido identificadas como la clase S+N; y las regiones cuyas reflectividad poseen valores bajos con velocidades que siguen un patrón aleatorio fueron clasificadas como N.

Cabe destacar que en general, se observa que la red ha clasificado como C+N a aquellas zonas donde existe clutter intenso, lo cual indica que la CNN no identifica la presencia de fenómeno meteorológico. Este resultado coincide con el resultado del estudio realizado en las Secciones 4.4, 5.5 y 6.5 a partir de observar las regiones en donde el clutter terrestre es filtrado y se dificulta la reconstrucción del espectro del fenómeno o bien estimar correctamente sus momentos a partir de la DEP. Tanto los análisis de las secciones mencionadas como los resultados de la clasificación presentados, sugieren que por la altura a la que se encuentra el fenómeno, la altura del terreno y la elevación de la antena del radar, las montañas en esas celdas de rango obstruyen la propagación de la onda impidiendo que las contribuciones del fenómeno tengan un efecto apreciable en la señal recibida y como consecuencia las contribuciones del clutter terrestre sean las que dominen la composición de dicha señal.

A medida que se toma distancia de las zonas de clutter de mayor intensidad, en las cuales existen precipitaciones del fenómeno meteorológico en sus alrededores, la CNN comienza a clasificar las contribuciones de la señal como C+S+N, debido a que el fenómeno meteorológico posee una intensidad más significativa en relación a la del clutter terrestre. El comportamiento descrito se aprecia en la Figura 7.9(c) en el traspaso del color azul (C+N) al celeste (C+S+N), y luego al verde (S+N).

RMA-11

La PRI del barrido considerado es 2 ms, siendo la velocidad Doppler máxima no ambigua $v_a = 6,66$ m/s. El número de muestras en cada CPI es $M = 27$, por lo cual se entrenó una nueva red neuronal similar a la arquitectura número 6, pero con 27 neuronas en la capa de entrada. Para el entrenamiento y validación se generaron datos sintéticos con el mismo grillado empleado en la Sección 7.2.2.

Previo al procesamiento de los datos reales, en la Figura 7.10 se presenta la matriz de confusión para esta red utilizando los datos de validación, con el objetivo de dar una idea de su desempeño ya que dicha red no fue estudiada en las secciones previas. De la misma se observa que el desempeño es inferior al presentado para $M = 64$, lo que es esperado debido a que se cuenta con un menor número de muestras llevando a una estimación del espectro de menor resolución.

Clases verdaderas	C + N	12888	905	584	85	89.1%	10.9%
	C + S + N	2829	11048	122	569	75.8%	24.2%
	N	125	16	13214	865	92.9%	7.1%
	S + N	166	197	1940	12046	84.0%	16.0%
		80.5%	90.8%	83.3%	88.8%		
		19.5%	9.2%	16.7%	11.2%		
		C + N	C + S + N	N	S + N	Clases predichas	

Figura 7.10: Matriz de confusión de la CNN para $M = 27$.

A diferencia del caso anterior, para este conjunto de datos se representa gráficamente el barrido completo. En las Figuras 7.11(a) y 7.11(b) se presentan los PPIs de la reflectividad y de la velocidad Doppler media obtenidos empleando el algoritmo PPP. A partir del conocimiento del terreno, se puede identificar la cadena montañosa situada al Oeste, la que coincide con los valores altos de reflectividad y valores de velocidad alrededor de cero. Por otro lado, se observa el fenómeno meteorológico en la dirección Sureste identificado a partir de los valores intermedios de reflectividad y la forma en la que varía la velocidad. La composición de la señal debido a reflexiones en el resto de la región no posee otra contribución más que la del ruido. Con el propósito de validar el funcionamiento de la CNN, a diferencia del conjunto de datos previos, de antemano se puede decir que en las zonas en las que existen reflexiones debidas al clutter terrestre prácticamente no existe influencia del fenómeno meteorológico y viceversa, en las zonas en las que existen reflexiones debidas al fenómeno meteorológico no existe influencia del clutter terrestre.

En la Figura 7.11(c) se muestra el resultado de la clasificación de la composición de la señal meteorológica utilizando la red neuronal. En líneas generales, los resultados de la clasificación, se corresponden a lo indicado sobre la información brindada por las Figuras 7.11(a) y 7.11(b). Si se observa detalladamente se aprecia que en algunas pequeñas regiones que corresponden a las zonas identificadas como clutter terrestre la red clasifica erróneamente como C+S+N (píxeles celeste en medio de la región mayormente azul, correspondiente a la clase C+N). Sin embargo, desde el punto de vista práctico no son errores significativos y en cualquier caso un error entre estas dos clases llevará a que se aplique un dado filtro de clutter. Por otro lado, en la región identificada como fenómeno meteorológico la red en ningún caso indica la existencia de clutter, aunque

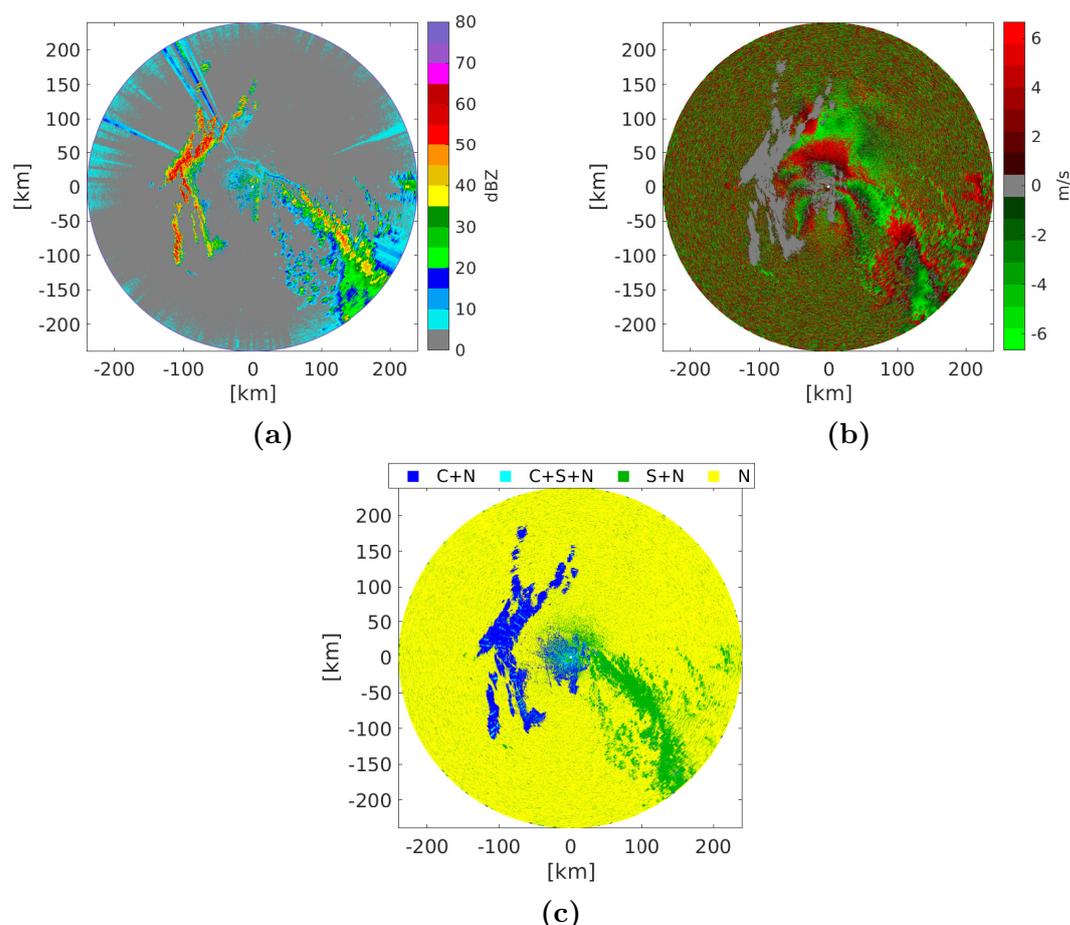


Figura 7.11: Resultados del procesamiento de los datos reales. (a) PPI de la reflectividad. (b) PPI de la velocidad Doppler media. (c) Clasificación utilizando la CNN.

es difícil determinar algún posible error entre las clases S+N y N. Sin embargo, esto tampoco significa un problema porque ninguna de esas clases determinará que deba aplicarse un filtro de clutter.

Desde el punto de vista cualitativo, los resultados obtenidos para los radares RMA-12 y RMA-11 son muy satisfactorios. Se concluye que las CNNs entrenadas con datos sintéticos son capaces de generalizar y predecir correctamente la composición de la señal meteorológica para los datos empleados. Como ocurrió en el filtrado de clutter y la estimación de momentos, los resultados de la clasificación también confirman que el modelo de señal, empleado en la síntesis de los datos de entrenamiento, representa adecuadamente a las mediciones del radar, permitiendo generar configuraciones meteorológicas diversas, bien etiquetadas y con el volumen necesario, supliendo la necesidad de contar con una base de datos adquiridos con esas características, un factor que suele limitar el uso de este tipo de herramientas.

7.4. Modo staggered 2/3

En esta sección se estudia el método propuesto para el modo de operación *staggered*. Si bien el algoritmo se puede extender a cualquier relación entre los PRIs, sin pérdida de generalidad para el presente estudio se adopta la relación entre PRIs 2/3. El enfoque es el mismo que el utilizado para PRI uniforme, es decir se toman las DEP estimadas de los datos como el insumo de entrada a la red que realizará la clasificación de la señal. Como se describió en la Sección 4.2.1, la secuencia staggered no posee un espaciado uniforme entre muestras, por lo cual previo a la estimación de su DEP se interpolan con ceros las muestras IQ en el dominio del tiempo con el objetivo de crear una secuencia uniforme. Esto último conlleva que la capa de entrada de la CNN para el modo staggered es, en general, de mayor número de neuronas que para el modo convencional. Como también se describió en la Sección 4.2.1, otra diferencia consiste en que, como consecuencia de la interpolación, para *staggered* 2/3 además de los espectros originales del clutter y del fenómeno, la DEP presenta cuatro réplicas para cada uno. Este efecto motiva un pequeño cambio en cuanto al grillado de la generación de los datos de entrenamiento y validación. El mismo es igual al presentado en la Sección 7.2.2, excepto para σ_p . En esta ocasión, para σ_p se utilizan 12 valores uniformemente espaciados en el intervalo $0,04v_a$ a $0,2v_a$, debido a la gran superposición que presentan las réplicas del espectro del fenómeno meteorológico para valores altos de σ_p .

7.4.1. Estudio de diferentes CNNs

Análogamente a lo realizado para el modo convencional, se entrenan 10 redes convolucionales de diferentes tamaños y se estudian sus desempeños sobre los datos de validación. En la Tabla 7.3 se muestran las capas ocultas de las 10 arquitecturas, donde se hizo uso de la notación x, y para las capas convolucionales de una dimensión (conv1d) descrita en la Sección 7.3.1. Para este estudio en particular se considerará que se cuenta con CPIs compuestos de $M = 64$ pulsos, que, luego de la interpolación con ceros y la estimación del espectro, da como resultado DEPs con longitud igual a 158 muestras, lo cual coincide con el número de neuronas de la capa de entrada. El entrenamiento de las CNNs se realiza utilizando los mismos valores de los hiperparámetros, librerías y hardware presentado en la Sección 7.3.1.

En la Figura 7.12 se muestran los resultados de las tres métricas elegidas para el estudio de las 10 arquitecturas. De las Figuras 7.12(a) y 7.12(b) se observa que la arquitectura número 5 presenta el menor valor de loss y el mayor accuracy, lo cual la posiciona como posible candidata a ser elegida. También es importante notar que el accuracy obtenido para todas las arquitecturas es mayor a 0.85, y que los valores para cada arquitectura no difieren por mucho. Por su parte, de la Figura 7.12(c) se

Arquitectura	conv1d	conv1d	conv1d	densa	densa	densa	densa	número de parámetros a entrenar
1	5, 5			50	40			40784
2	5, 5			100	80			85534
3	5, 5	5, 5		50	40			39914
4	5, 5	5, 5		100	80			83664
5	5, 5	5, 5	5, 5	50	40			39044
6	5, 5	5, 5	5, 5	100	80			81794
7	10, 10	10, 10	10, 10	50	40	20		70624
8	10, 10	10, 10	10, 10	100	80	50		145564
9	5, 5	5, 5	10, 10	100	60	30		149784
10	20, 20	10, 10	5, 5	100	50	30	20	73069

Tabla 7.3: Diferentes arquitecturas de CNN estudiadas. Modo *staggered*

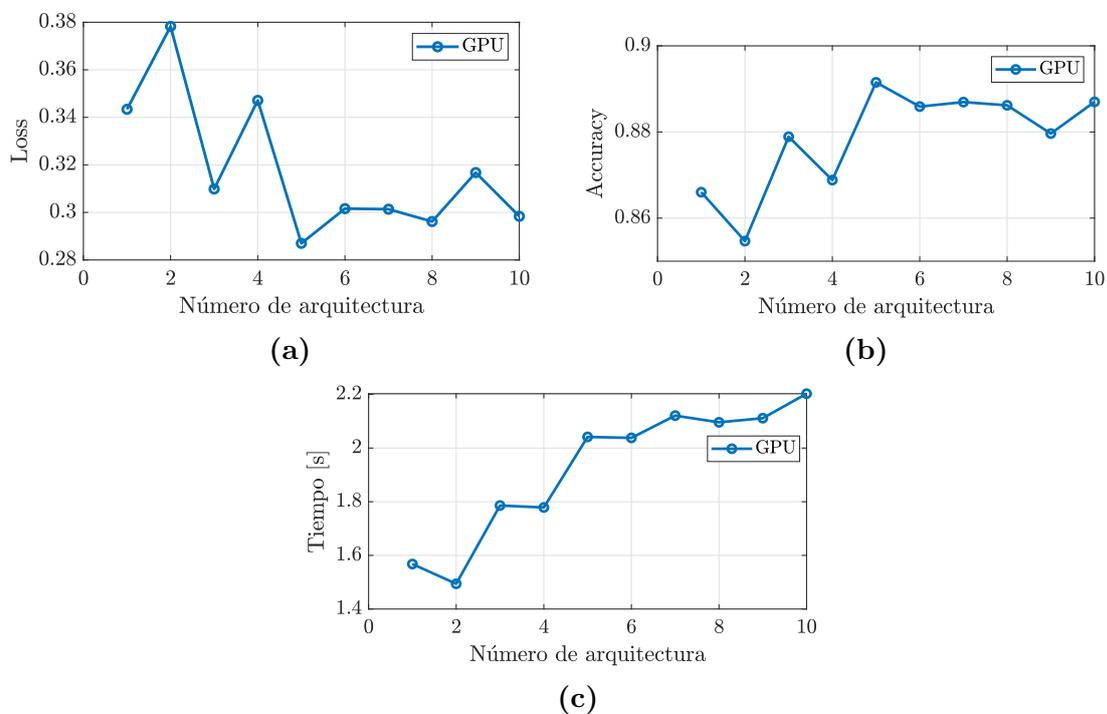


Figura 7.12: Métricas del estudio de las diferentes arquitecturas de CNN para modo *staggered*. (a) Loss. (b) Accuracy. (c) Tiempo de predicción promedio.

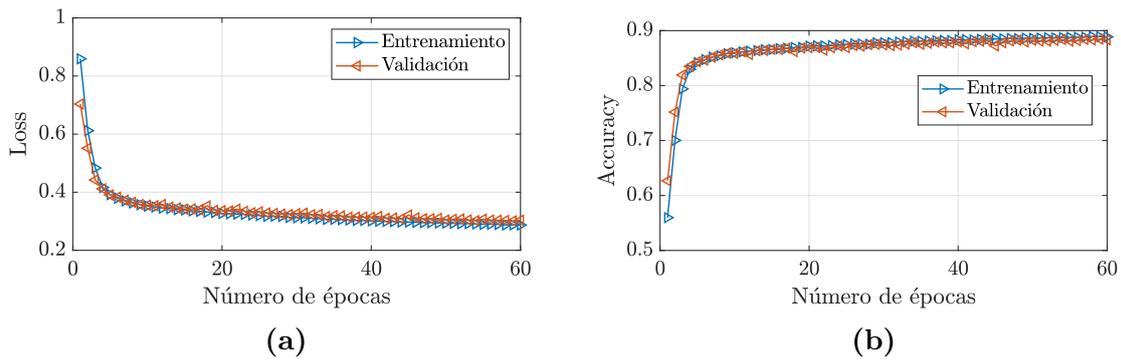


Figura 7.13: Desempeño del entrenamiento y la validación en el modo staggered. (a) Loss. (b) Accuracy.

advierte que los tiempos de predicción aumentan con el número de capas ocultas que posee la red, no así con el número de parámetros a entrenar. Se realizaron 10 corridas por arquitectura con el objetivo de calcular valores promedios para los tiempos de predicción. De los resultados obtenidos para el accuracy y el tiempo de predicción, se elige a la arquitectura número 5 para resolver el problema de la clasificación de la composición de la señal meteorológica.

7.4.2. Entrenamiento y validación de la CNN elegida

Para el entrenamiento se emplean los mismos hiperparámetros que se presentaron en la Sección 7.3.2. Las Figuras 7.13(a) y 7.13(b) muestran las funciones de loss y el accuracy para los datos de entrenamiento y validación, respectivamente, en función del número de épocas. De ambas figuras se observa que la CNN aprendió a identificar correctamente la composición de la señal meteorológica, presentando un accuracy de aproximadamente 89% para los datos de validación. Con el objetivo de profundizar en el entrenamiento de la CNN, en la Figura 7.14 se observa la matriz de confusión utilizando los datos de validación. En esta oportunidad, se nota que la tasa de FP y FN aumentaron, respecto de la matriz de confusión obtenida para el modo convencional.

En particular, se destaca el error en la clasificación que la red comete entre las clases $C + S + N$ y la clase $C + N$. Estos errores están asociados principalmente a situaciones en las cuales σ_p toma valores altos. En esos casos existe una gran superposición entre las réplicas de los espectros, lo que lleva a que el espectro del fenómeno quede enmascarado y la red no pueda distinguirlo del ruido. Por lo tanto, sólo identifica, erróneamente, la presencia de clutter y ruido. Este tipo de situaciones se analizan en la Sección 7.4.3.

Clases verdaderas	C + N	12993	1025	258	26	90.8%	9.2%
	C + S + N	2344	11854	59	237	81.8%	18.2%
	N	39	18	13361	1029	92.5%	7.5%
	S + N	11	50	1674	12621	87.9%	12.1%
		84.4%	91.6%	87.0%	90.7%		
		15.6%	8.4%	13.0%	9.3%		
		C + N	C + S + N	N	S + N	Clases predichas	

Figura 7.14: Matriz de confusión de la CNN entrenada utilizando los datos de validación.

7.4.3. Experiencias con datos sintéticos

Con el objetivo de medir el desempeño de la CNN en condiciones conocidas se repite el análisis con datos sintéticos pero para el caso *staggered*. En esta oportunidad se realizan 10 experimentos divididos en dos grupos, con las mismas consideraciones realizadas que para el modo de operación convencional. Para los primeros 4 experimentos, se simulan datos IQ de la situación S + N y se varía la SNR de 0 dB a 30 dB. Para los restantes 6 experimentos, se simula datos IQ de la situación C + S + N: del cuarto al octavo se varía σ_p de $0,04v_a$ a $0,2v_a$, y para el noveno y décimo, se varía la SNR de 0 dB a 30 dB. En todos los experimentos, por cada valor del parámetro variable, se generan 1000 realizaciones. Los parámetros generales de las simulaciones se encuentran en la Tabla 7.4

En los primeros 4 experimentos, dado que solo existe fenómeno y ruido, se fijan los valores de v_p y σ_p : en el primer experimento $v_p = 0$ m/s y $\sigma_p = 0,1v_a$, en el segundo experimento $v_p = 0,3v_a$ m/s y $\sigma_p = 0,1v_a$, en el tercer experimento $v_p = 0$ m/s y $\sigma_p = 0,05v_a$, en el cuarto experimento $v_p = 0,3v_a$ m/s y $\sigma_p = 0,05v_a$. La elección de los dos valores de velocidades seleccionados se debe a tener situaciones en las que existe superposición del espectro del clutter y del fenómeno ($v_p = 0$ m/s), y situaciones en las que no exista superposición, o la misma no sea significativa desde el punto de vista práctico.

La Figura 7.15 muestra los resultados de las clasificaciones para los primeros cuatro experimentos. En todos se observa que para valores de SNR (< 5 dB) la CNN elige erróneamente la clase N, lo cual se explica de igual manera que para el modo convencional. Además, se aprecia que este tipo de error disminuye a medida que se reduce el

Parámetro	Símbolo	Valor
Frecuencia de portadora	F_c [GHz]	5,6
Longitud de onda	λ [cm]	5,35
Nro. de muestras (pulsos)	M	64
PRI 1	T_1 [ms]	0,8
PRI 2	T_2 [ms]	1,2
Velocidad máxima no ambigua	v_a [m/s]	33.5
Ancho teórico del clutter	σ_t [m/s]	0.28
Potencia del fenómeno	p_p [u.a]	1

Tabla 7.4: Parámetros para la simulación.

valor de σ_p , debido a que al poseer un ancho espectral más angosto y mantenerse la potencia constante, el espectro del fenómeno alcanza valores mayores respecto del nivel de ruido favoreciendo que sea identificado en la composición de la señal. Por otro lado, para velocidad $v_p = 0$ m/s, de las Figuras 7.15(a) y 7.15(c) se observa que la CNN elige erróneamente, con poca probabilidad, la clase C + S + N para todos los valores de SNR, y que para valores de SNR (< 5 dB) también presenta cierta probabilidad de elegir erróneamente la clase C + N. Estos errores se incrementan a medida que disminuye σ_p . Los dos resultados anteriores son esperados, y se deben a la superposición existente entre las DEPs del clutter y del fenómeno. Finalmente, las Figuras 7.15(b) y 7.15(d) corresponden a la situación más favorable, es decir, cuando la superposición entre réplicas del espectro es baja ya que $v_p = 0,3v_a$. En esta condición se observa que la CNN sólo identifica la clase N en lugar de S+N en una proporción relativamente baja y únicamente para valores de SNR (< 5 dB).

Para los restantes experimentos, dada la presencia de clutter terrestre, además de los parámetros del fenómeno se fija el valor de CSR. En el quinto experimento: $v_p = 0$ m/s, SNR = 15 dB y CSR = 40 dB. En el sexto experimento: $v_p = 0,3v_a$ m/s, SNR = 15 dB y CSR = 40 dB. En el séptimo experimento: $v_p = 0$ m/s, SNR = 5 dB y CSR = 40 dB. En el octavo experimento: $v_p = 0$ m/s y SNR = 15 dB y CSR = 10 dB. En el noveno experimento: $v_p = 0$ m/s, $\sigma_p = 0,1v_a$ y CSR = 40 dB. En el décimo experimento: $v_p = 0$ m/s, $\sigma_p = 0,1v_a$ y CSR = 10 dB.

La Figura 7.16 muestra los resultados de las clasificaciones para el segundo grupo de experimentos. En particular, en las Figuras 7.16(a), 7.16(b), 7.16(c), 7.16(d) se observan los resultados variando σ_p . De las cuatro figuras se aprecia que para valores altos de este parámetro, la CNN elige erróneamente la clase C + N. Este resultado se debe a la superposición entre las réplicas del espectro del fenómeno, lo cual hace que aumente el piso de la DEP y la red se confunda con situaciones en las que sólo existe clutter y ruido. Para los experimentos quinto y octavo, de las Figuras 7.16(a) y 7.16(d)

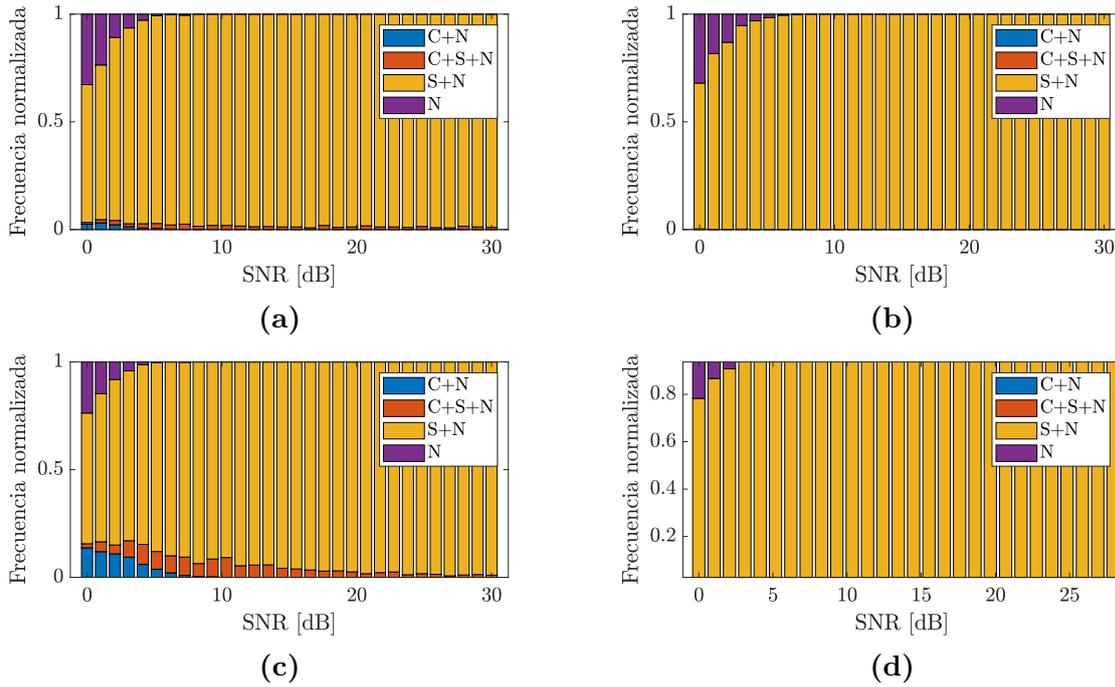


Figura 7.15: Análisis de error en la clasificación de la clase $S + N$ para el modo staggered. (a) Primer experimento, $v_p = 0$ m/s, $\sigma_p = 0,1v_a$. (b) Segundo experimento, $v_p = 0,3v_a$ m/s, $\sigma_p = 0,1v_a$. (c) Tercer experimento, $v_p = 0$ m/s, $\sigma_p = 0,05v_a$. (d) Cuarto experimento, $v_p = 0,3v_a$ m/s, $\sigma_p = 0,05v_a$.

se observa que para valores bajos de σ_p la CNN se confunde con la clase $S + N$, siendo más significativo a medida que disminuye la CSR. Esta dependencia con la CSR es esperada, debido a que ambos espectros están superpuestos, la red no logra distinguir el espectro del clutter sobre el del fenómeno. Finalmente, en las Figuras 7.16(e) y 7.16(f) se observan los resultados de la clasificación variando el valor de SNR. Para valores bajos de SNR la red elige erróneamente la clase $C + N$, ya que el espectro del fenómeno es indistinguible por sobre el espectro del ruido. Además, a medida que disminuye el valor de CSR, la red comienza a reportar estimaciones erróneas de la clase $S + N$.

En general, la CNN entrenada para el modo *staggered* presenta buen desempeño utilizando datos sintéticos. El mismo se degrada en situaciones específicas (valores bajos de SNR, altos y valores bajos de σ_p , valores bajos de CSR, etc.), en los cuales es difícil distinguir la presencia del fenómeno o confundir el espectro del fenómeno con el del clutter o con el del ruido.

7.4.4. Procesamiento de datos reales

En esta sección se estudia el desempeño de la CNN empleando datos reales adquiridos con el radar argentino RMA-12. La medición fue adquirida el 1° de febrero de 2020, seis minutos después del registro de datos utilizado en la Sección 7.3.4 para el

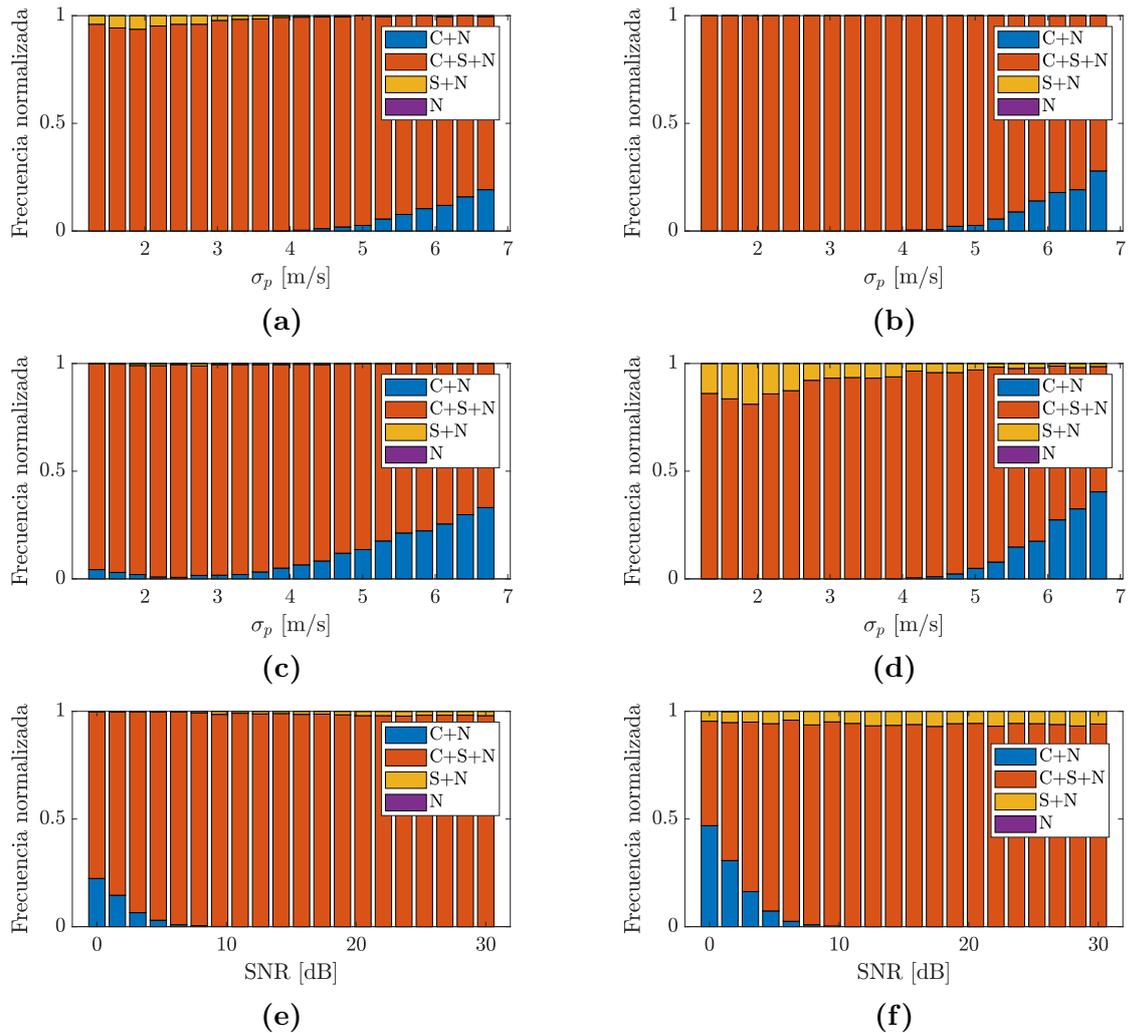


Figura 7.16: Análisis de error en la clasificación de la clase C + S + N para el modo staggered. (a) Quinto experimento, $v_p = 0$ m/s, SNR = 15 dB, CSR = 40 dB. (b) Sexto experimento, $v_p = 0,3v_a$ m/s, SNR = 15 dB, CSR = 40 dB. (c) Séptimo experimento, $v_p = 0$ m/s, SNR = 5 dB, CSR = 40 dB. (d) Octavo experimento, $v_p = 0$ m/s y SNR = 15 dB, CSR = 10 dB. (e) Noveno experimento, $v_p = 0$ m/s, $\sigma_p = 0,1v_a$, CSR = 40 dB. (f) Décimo experimento, $v_p = 0$ m/s, $\sigma_p = 0,1v_a$, CSR = 10 dB.

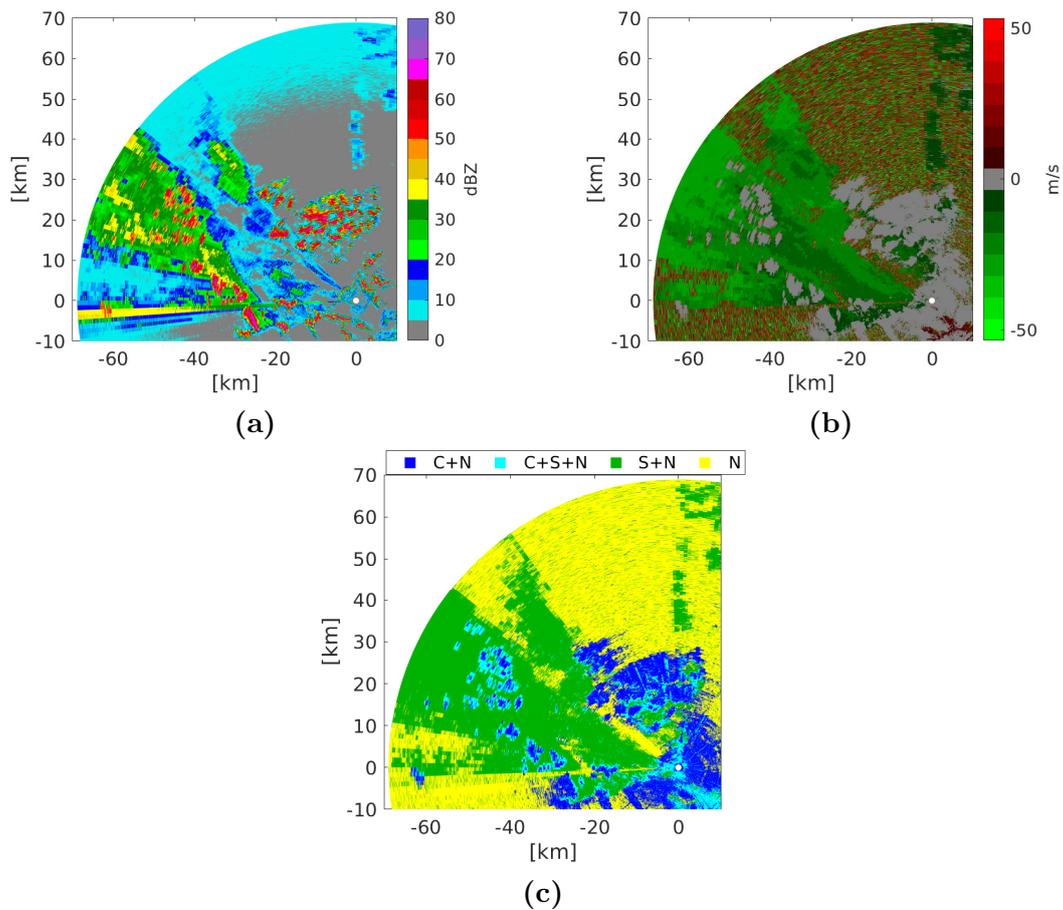


Figura 7.17: Resultados del procesamiento de los datos reales en modo *staggered*. (a) PPI de la reflectividad. (b) PPI de la velocidad Doppler media. (c) Clasificación utilizando la CNN.

modo de operación convencional. Los datos se midieron utilizando el modo *staggered* 2/3, con $T_1 = 0,5$ ms y $T_2 = 0,75$ ms, lo cual equivale a una velocidad máxima no ambigua $v_a = 53,33$ m/s.

Como se hizo en la Sección 7.3.4 se pondrá el foco en $1/4$ (90°) de un barrido completo (360°). Las Figuras 7.17(a) y 7.17(b) muestran los PPIs de reflectividad y de velocidad Doppler media para el conjunto de datos descrito. Ambos parámetros poseen las mismas características que el conjunto de datos utilizado en la Sección 7.3.4, exceptuando que la velocidad no presenta los saltos abruptos en sus valores como consecuencia de que el modo de operación *staggered* incrementa la velocidad máxima no ambigua, tal como se describió en la Sección 4.4 para este mismo conjunto de datos.

Por otro lado, la Figura 7.17(c) muestra la clasificación de los datos utilizando la CNN. De la misma se identifican las 4 composiciones de señal. Es importante notar la gran correspondencia entre este resultado y los obtenidos en las Figuras 7.17(a) y 7.17(b). Al igual que para el modo convencional se observa que en las regiones de clutter intenso, no hay presencia de fenómeno meteorológico, lo cual está en concordancia con los resultados obtenidos en las Secciones 4.4 y 6.5 respecto de la estimación de

velocidad y ancho del espectro en esas zonas. Desde el punto de vista cualitativo, los resultados obtenidos son muy alentadores. Se observa que la CNN predijo correctamente la composición de la señal para los datos empleados. Además, estos resultados nuevamente confirman que el modelo de señal empleado en la síntesis de los datos de entrenamiento representa satisfactoriamente las mediciones del radar.

7.5. Conclusiones

En este capítulo se introdujo un método de clasificación de la composición de la señal de radar meteorológico basado en el uso de machine learning, específicamente, de redes neuronales convolucionales. La señal recibida por el radar se divide en cuatro posibles clases, *clutter + ruido*, *clutter + fenómeno + ruido*, *fenómeno + ruido* y *ruido*. El entrenamiento se realiza utilizando datos sintéticos abarcando de esta forma un gran número de configuraciones meteorológicas posibles. Para ello se dividió el espacio de parámetros de interés (v_p , σ_p , CSR, SNR) en grillas uniformemente espaciadas en intervalos realistas de configuraciones meteorológicas.

Una vez presentado el algoritmo y la generación de los datos de entrenamiento y validación se dividió el capítulo en dos secciones: la primera para el análisis del modo convencional de operación del radar, y la segunda para el análisis del modo staggered 2/3. Para ambas, se realizó un estudio de diferentes tamaños y número de capas ocultas de CNNs con el objetivo de analizar el desempeño de las mismas sobre los datos de validación. Como métricas se adoptaron el loss, el accuracy y el tiempo de predicción. Una vez seleccionada la arquitectura de mejor desempeño para cada modo de operación, se mostraron detalles de sus entrenamientos, en particular, mediante la matriz de confusión se observaron los porcentajes de aciertos y errores de las cuatro clases.

Para ambos modos, una vez entrenada la CNN se analizó su desempeño empleando datos sintéticos mediante simulaciones numéricas de tipo Monte Carlo. El objetivo consistió en profundizar en aquellas situaciones en las que la red se equivoca. Debido a la alta dimensionalidad del problema, se eligió variar una magnitud, manteniendo fijas las otras. Para el modo convencional se realizaron 8 experimentos: los cuatro primeros se correspondían a situaciones de S + N, y los restantes cuatro a situaciones C + S + N. Por otro lado, para el modo staggered se realizaron 10 experimentos, de los cuales: los cuatro primeros se correspondían a situaciones S + N, y los restantes 6 a situaciones C + S + N. De forma general, los resultados obtenidos para ambos modos de operación fueron muy buenos. En la mayoría de las situaciones se obtuvieron tasas de acierto mayores al 90 %, y se observó que la degradación en la clasificación ocurre cuando se dificulta distinguir la composición de la señal a partir de su espectro, como son las situaciones de valores bajos de SNR, CSR, velocidades cercanas al origen, y

valores altos y bajos de σ_p .

Además, se validó el desempeño del método propuesto utilizando datos adquiridos con radares meteorológicos argentinos. Para el modo convencional de operación, se utilizaron datos de los radares RMA-12 y RMA-11. Para el modo *staggered* se emplearon datos adquiridos con el radar RMA-12. En general, la red mostró una alta capacidad para clasificar la composición de señal con los datos empleados. Los resultados obtenidos fueron corroborados con los PPI de la reflectividad y de la velocidad Doppler media para cada situación. Se reafirmó lo concluido en la Sección 4.4 respecto de que en las regiones de clutter muy intenso las montañas obstruyen la propagación de la onda electromagnética hacia el fenómeno, haciendo que la influencia del mismo en la señal recibida no sea significativa. Con estos resultados, se comprobó que el modelo de generación de datos sintéticos se ajusta bien a las observaciones meteorológicas. Una vez entrenada la red, la misma puede procesar los datos en bloques (varios CPIs y todo los radiales), haciendo del método un buen candidato para implementación en tiempo real.

En relación a la red propuesta para clasificar la composición de la señal en el modo de operación *staggered*, se consideró la relación entre PRIs 2/3. Sin embargo, el método propuesto puede ser extendido para ser utilizado con cualquier relación de PRIs, o incluso con estrategias que empleen más de dos PRIs. En estos casos lo único que cambiaría es que los ceros de la interpolación ocuparían lugares diferentes a los resultantes de usar 2/3, y por lo tanto las réplicas de los espectros originales caerán en posiciones de frecuencia diferentes. Por lo tanto, será necesario entrenar la red empleando datos sintéticos que posean las características propias de los espectros resultantes para cada situación considerada.

Por último y no menos importante, considerando ampliar su uso en otros contextos de aplicación, se resalta que el método propuesto admite otros modelos matemáticos a la hora de generar sintéticamente las señales de radar. En [7] se afirma que cerca del 25 % de los espectros de los fenómenos meteorológicos no sigue una forma gaussiana, sino que poseen formas más complejas. Combinando los modelos de generación de los datos sintéticos, este tipo de situaciones pueden ser contempladas, lo que lleva a pensar que existe la posibilidad de contar con una CNN que mejore la tasa de aciertos al momento de procesar mediciones reales de radar.

Capítulo 8

Conclusiones

“Si he sido capaz de ver más lejos, es porque me he parado sobre los hombros de gigantes.”

— ISAAC NEWTON

En esta tesis se realizaron diferentes aportes relacionados con el procesamiento de la señal de radar meteorológico Doppler. Específicamente, se abordaron el filtrado de clutter terrestre, la estimación de momentos espectrales del fenómeno meteorológico y la clasificación de la composición de la señal. En cada línea se consideraron estrategias que se aplican tanto para el modo convencional de operación del radar, es decir con período de repetición de pulso uniforme, como para el modo *staggered*, es decir con períodos de repetición de pulso alternados.

En primer lugar, se realizó una breve introducción del estado del arte para este tipo de aplicaciones. Se describieron una serie de algoritmos conocidos en la literatura especializada y que en muchos casos corresponden a métodos que se utilizan ampliamente en el procesamiento de la señal de radares operativos. Se discutieron sus ventajas y desventajas.

Posteriormente se describieron los componentes principales del radar Doppler meteorológico, su funcionamiento y el modelo de la señal recibida. También se introdujeron conceptos importantes como volumen de resolución, ambigüedades, tanto en rango como en velocidad, la conformación y el muestreo de la señal a la salida del receptor. Se presentó el modo de operación *staggered* como solución a la relación de compromiso existente entre el rango máximo no ambiguo que se puede observar y la velocidad máxima no ambigua que se puede medir. Además, se describieron con mayor detalle los algoritmos más relevantes en la temática y que en el marco de la tesis se utilizan como patrón al momento de comparar desempeños con los métodos que se proponen. Entre ellos para el modo convencional de operación se encuentran PPP, para la estimación de momentos espectrales; y GMAP y GMAP-TD, para el filtrado de clutter terrestre; y en lo que respecta al modo de operación *staggered* SPPP y DA, para la

estimación de momentos espectrales; y GMAP-TD, para el filtrado de clutter terrestre. Asimismo, se realizó una breve introducción a machine learning y deep learning, en la cual se describieron los conceptos y algoritmos necesarios para entender el uso de estas herramientas en las diferentes aplicaciones presentadas a lo largo de la tesis.

Una vez presentado el problema a resolver, se procedió a describir los métodos originales desarrollados durante el trabajo doctoral. En primer lugar se propuso una corrección al ancho espectral del clutter. Este pequeño aporte está motivado sobre un problema práctico que se presenta en aquellos algoritmos que remueven el clutter terrestre a partir de aplicar una máscara en el dominio del espectro, como es el caso de GMAP. En esos casos, debido a que se cuenta con un número pequeño de muestras, el efecto de la ventana es apreciable y debe ser tenido en cuenta, porque de no hacerlo la remoción no es completa y los momentos espectrales se sesgan significativamente. La corrección propuesta consiste, simplemente, en aproximar la densidad espectral de energía de la ventana por una función gaussiana y corregir el ancho espectral nominal sumando el ancho espectral obtenido a partir del ajuste. Debido a que la función gaussiana a ajustar varía con la ventana que se emplee y con el número de muestras, se presentaron los resultados del ajuste para dos ventanas diferentes. Finalmente, se analizó con un ejemplo como opera la corrección y el efecto de no considerarla.

Por otro lado, se introdujo el método GMAP-NU como solución al problema de filtrado de clutter terrestre y estimación de momentos espectrales del fenómeno para señales adquiridas en el modo de operación *staggered*. La idea del método es muy intuitiva, debido a que en la dimensión tiempo lento la señal resultante en el modo de operación *staggered* posee un espaciado temporal no uniforme, se propone reconstruir la señal que se obtendría si el espaciado temporal fuera uniforme y en una etapa posterior aplicar un método de filtrado convencional. Para ello GMAP-NU combina dos métodos existentes, por un lado utiliza un algoritmo que a partir de una señal muestreada de forma no uniforme reconstruye su espectro en una grilla uniforme, y mediante su antitransformada de Fourier obtiene una secuencia uniformemente muestreada. Luego, emplea el algoritmo GMAP para filtrar el clutter y realizar las estimaciones de los momentos espectrales. Mediante simulaciones numéricas de tipo Monte Carlo se analizó el desempeño de GMAP-NU y el mismo se comparó con el de GMAP bajo las mismas condiciones de simulación pero utilizando señales muestreadas uniformemente. Se obtuvieron resultados satisfactorios en el rango de los parámetros utilizados, los mismos resultaron comparables a los de GMAP, demostrando de esta forma el correcto funcionamiento de la etapa de reconstrucción espectral. El algoritmo GMAP-NU es atractivo debido a que permite realizar el filtrado con algoritmos fuertemente probados que operan con tiempo de muestreo uniforme. Sin embargo, en la práctica presenta una limitación respecto de la velocidad máxima no ambigua que puede resolver. En general, para dos PRIs, T_1 y T_2 , la velocidad máxima no ambigua, v_a , resulta inversamente pro-

porcional a la diferencia $T_1 - T_2$, mientras que para GMAP-NU la velocidad máxima no ambigua es inversamente proporcional al promedio $0,5(T_1 + T_2)$, llevando a que, por ejemplo, para una relación de PRIs $2/3$ se resuelva como máximo una velocidad de $2v_a/5$. Esta restricción la impone el algoritmo de reconstrucción y es una situación análoga a la del teorema de muestreo para secuencias uniformemente muestreadas, respecto a la relación que debe poseer la frecuencia de muestreo y la frecuencia máxima de la señal para poder reconstruir la señal original a partir de sus muestras.

En segunda instancia, se propuso el algoritmo ASPASS como alternativa a GMAP-NU para la solución al problema de filtrado de clutter y estimación de momentos espectrales del fenómeno meteorológico, con el objetivo de explotar el rango máximo de velocidades que brinda el modo de operación *staggered*, debido a que no presenta la limitación en la velocidad Doppler media encontrada en GMAP-NU. Este método surge inspirado en las ideas del algoritmo GMAP, incluso se lo puede considerar una extensión de este último para procesar señales adquiridas en el modo de operación *staggered* del radar. Si bien el algoritmo admite cualquier relación de PRIs, sin pérdida de generalidad, se desarrolló usando dos PRIs (T_1, T_2) tal que $T_1/T_2 = 2/3$, debido a que esta relación es la más empleada como consecuencia de presentar un buen balance entre el valor de velocidad máxima no ambigua y los errores de estimación [17]. En pos de estudiar el desempeño de ASPASS se optó por dos tipos de análisis que se repitieron para los demás métodos propuestos a lo largo de la tesis. En primer lugar, se emplearon simulaciones numéricas de tipo Monte Carlo que permiten tener control sobre las situaciones y los parámetros considerados. En segunda instancia, se recurrió al procesamiento de mediciones reales de radar que permitieran validar la operación de ASPASS conforme los resultados obtenidos por medio de las simulaciones.

Las simulaciones involucran la generación del dato sintético correspondiente a la señal que el radar obtiene en la dimensión tiempo lento, a partir de un modelo estadístico que la representa adecuadamente [3]. Se contempla la posibilidad de que la señal posea las diferentes composiciones que aparecen en un radar operativo y en los análisis dicha composición se varía, conforme el estudio que se desea realizar. Para cada corrida, la realización de la señal generada es procesada con los métodos que correspondan, dando como resultado los estimados de los momentos espectrales del fenómeno meteorológico. Como medida de desempeño se considera el sesgo y la desviación estándar, los cuales se evalúan como los promedio muestrales de sus respectivos valores obtenidos luego de cada corrida.

En el caso de ASPASS, las simulaciones se separaron en diferentes experimentos, en los cuales se varían la velocidad Doppler media o el ancho espectral de la señal meteorológica, mientras se mantienen fijos los demás parámetros. Además, los experimentos se dividieron en dos escenarios: con y sin la presencia de clutter. El desempeño de ASPASS se comparó con el de SPPP y DA cuando el clutter está ausente, y con

la versión *staggered* de GMAP-TD cuando el clutter contamina la señal. Para ambos escenarios los resultados obtenidos fueron comparables con los métodos mencionados anteriormente e inclusive ASPASS mostró menor sensibilidad a las réplicas de clutter que GMAP-TD en las estimaciones.

Además del desempeño de los métodos desde el punto de vista de los errores de estimación, en este tipo de aplicaciones un aspecto importante a tener en cuenta es su costo computacional. Los valores de una configuración estándar del radar, permiten dar una noción de los tiempos involucrados. Para eso se puede partir de considerar que el tiempo de repetición de pulso es de $1000 \mu\text{s}$, lo que determina un rango máximo no ambiguo de 150 km. Una frecuencia de muestreo a la salida del receptor de 5 MHz equivale a muestrear la señal en rango cada 30 m, con lo que se obtiene un total de $150 \text{ km}/30 \text{ m} = 5000$ celdas de rango, bajo la simplificación de que la ventana de recepción es igual al tiempo de repetición de pulso. Por otro lado, si 64 es el número de pulsos en 1° en acimut, es decir un CPI contiene 64 pulsos, entonces el radar completará un barrido de 360° en acimut en aproximadamente 23 segundos. En ese tiempo el número de muestras adquiridas es $5000 \times 64 \times 360 = 115.200.000$ y el número de CPIs a procesar es $5000 \times 360 = 1.800.000$. Además del procesamiento de la señal, en el tiempo entre barridos es necesario que el sistema transmita y guarde los datos en memoria. Si bien este ejemplo solo sirve para mostrar órdenes de magnitud de los tiempos involucrados y lograr o implementar algoritmos eficientes desde el punto de vista del costo computacional no conforma un objetivo de este trabajo, para completar el estudio comparativo de los métodos también se consideró este aspecto.

Con esta motivación, también se realizó un estudio comparativo entre ASPASS y GMAP-TD en términos de costo computacional. Debido a que se dificulta contar operaciones por tratarse de métodos iterativos, se compararon los tiempos de ejecución y los números de iteraciones promedio hasta la convergencia de cada uno de los métodos. Los resultados arrojaron que ASPASS supera a GMAP-TD en ambas métricas, estando cerca de un orden de magnitud por debajo en lo que hace al tiempo de ejecución. Cabe destacar que esto es un resultado esperado, debido que opera principalmente en el dominio de la frecuencia, lo cual involucra algoritmos eficientes desde el punto de vista computacional, mientras que GMAP-TD opera en el dominio del tiempo realizando la inversión de una matriz en cada iteración.

Para el procesamiento de datos reales se utilizaron mediciones obtenidas con el radar argentino RMA-12. Se emplearon conjuntos de datos correspondientes a tres barridos, dos de ellos adquiridos en el modo convencional de operación del radar y el tercero adquirido en el modo de operación *staggered* 2/3. Con estos conjuntos, en primer lugar, se comprobó la capacidad de incrementar el rango máximo no ambiguo que ofrece el modo de operación *staggered*.

En general, los resultados obtenidos fueron satisfactorios. Se observó que ASPASS

en las zonas de clutter fue capaz de filtrarlo y estimar los momentos espectrales del fenómeno, cuando el mismo se encuentra presente. A la salida de la etapa de procesamiento con ASPASS se observó una pocas zonas de reflectividad mayor a la esperada. En esas regiones se profundizó el análisis evaluando el espectro de las señales correspondientes a distintos CPIs ubicados en el mismo rango. Los resultados mostraron que cuando el clutter es muy intenso, el mismo obstruye las contribuciones de la señal proveniente del fenómeno meteorológico, o bien las mismas son muy débiles y quedan enmascaradas, haciendo que las estimaciones de los momentos espectrales reporten valores sesgados. Este efecto es común y depende del tipo de precipitación, su altura y además de las características del terreno.

Posteriormente se introdujo una nueva metodología, utilizando machine learning, para el procesamiento de la señal radar. En la misma se explota la estructura bien definida que posee la DEP de las señales meteorológicas para realizar las estimaciones de los momentos espectrales. En particular, como modelo de machine learning, se emplean redes neuronales artificiales, las cuales son entrenadas utilizando datos sintéticos. Esto último permite la creación de grandes bases de datos bien etiquetados contemplando gran diversidad de configuraciones meteorológicas, lo cual es una tarea muy difícil de realizar con mediciones reales para un mismo volumen de datos.

Inicialmente, el método fue aplicado a señales adquiridas en el modo convencional de operación del radar con PRI uniforme. Se diseñó una red neuronal con tres ramas, donde cada una posee una estructura densa y se utiliza para la estimación de CSR, v_p y σ_p , respectivamente. Se adoptó un esquema de clasificación para realizar las estimaciones de los momentos espectrales, en el cual para cada rama la capa de salida está constituida por un número determinado de neuronas o clases, activándose aquella a la que pertenece la DEP analizada. Para la generación de los datos sintéticos, se dividió el espacio de parámetros de la señal radar en una grilla tetradimensional contemplando intervalos de interés definidos a partir de la experiencia que se posee del conocimiento trabajando con datos reales.

Una vez elegida y entrenada la DNN se procedió a estudiar su desempeño utilizando un procedimiento análogo al seguido con ASPASS, a partir de simulaciones numéricas de tipo Monte Carlo y procesando mediciones reales de radar, con el sesgo y la desviación estándar de los estimados como métricas. El estudio se dividió en dos escenarios, cada uno contemplando la ausencia y la presencia de clutter terrestre. Para el primer escenario el desempeño de la red se comparó con el del algoritmo PPP, y para el segundo escenario con el de GMAP. En ambas ocasiones los resultados obtenidos fueron satisfactorios, obteniéndose para el primer escenario resultados comparables con PPP y para el segundo escenario mejores estimaciones de velocidad Doppler media y de ancho espectral que GMAP, no así para la estimación de potencia.

Para analizar el desempeño de la DNN sobre datos reales se emplearon mediciones

del radar RMA-12 y, nuevamente, se utilizaron los algoritmos PPP y GMAP para comparar desempeños. En general, se observaron buenos resultados, comparables con los de los métodos antes mencionados. También se verificó la capacidad de la red neuronal de funcionar correctamente en presencia y ausencia de clutter terrestre.

Desde el punto de vista del uso de redes neuronales, con respecto a otras aplicaciones este método tiene la gran ventaja de presentar un buen desempeño aún cuando es entrenado con datos sintéticos. Esto no es menor, debido a que permite crear una base de datos etiquetada que contemple numerosas situaciones. Esta ventaja radica en el hecho de que el modelo de DEP gaussiana tanto para el espectro del clutter como para el del fenómeno meteorológico se ajusta bien al espectro de las mediciones, o visto de otra manera, confirma que dicho modelo representa bien al espectro de las señales. Por otra parte, desde el punto de vista operativo, este método posee la ventaja de que no requiere de una etapa previa de identificación de clutter para determinar si se aplica o no filtrado. Al entrenar la red con situaciones que contemplan tanto la presencia como la ausencia de las contribuciones del clutter, la red implícitamente identifica que composición posee la señal recibida y opera conforme la situación que se le presenta.

Debido a que los resultados obtenidos para el modo de operación convencional fueron satisfactorios, el siguiente paso consistió en extender las ideas del algoritmo anterior para señales adquiridas en el modo de operación *staggered*, en particular, para una relación de PRI de 2/3. Lo que se buscó es que el algoritmo mantenga la esencia, tomando como insumo de entrada la DEP estimada de la señal. Sin embargo, es importante destacar que en este caso la señal se encuentra muestreada de forma no uniforme, por lo tanto previo a aplicar la transformada de Fourier se genera una señal con separación espacial uniforme a partir de interpolar con ceros. A raíz de dicha interpolación, en la DEP aparecen réplicas de los espectros originales del clutter y del fenómeno, aumentando el grado de complejidad del problema a resolver. No obstante, la metodología seguida en cuanto a la generación de los conjuntos de entrenamiento, validación y la manera de entrenar la red fue la misma que para el modo convencional, salvo la estructura de red adoptada para cada rama. En esta ocasión se utilizaron redes convolucionales en una dimensión.

Una vez elegida y entrenada la CNN se validó su desempeño utilizando datos sintéticos mediante simulaciones numéricas, y mediante el procesamiento de datos reales, repitiendo las métricas empleadas para los métodos anteriores. Las simulaciones se dividieron en dos escenarios, en los cuales el primero no contempla la presencia de clutter terrestre contaminando la señal, y el segundo sí. Además, para el primer escenario se comparó el desempeño de la CNN con el del algoritmo DA en la estimación de velocidad Doppler media y con SPPP en la estimación del ancho espectral. Para ambas estimaciones la CNN mostró mejor desempeño que los métodos antes mencionados, resaltando su utilidad en situaciones de valores de SNR medios y altos. Para el segundo

escenario, se comparó el desempeño de la CNN con el de ASPASS. En general, con la CNN se obtuvo mejor desempeño, en cuanto a errores relativos, para las estimaciones de velocidad Doppler media y ancho espectral, no así para las estimaciones de potencia. También se estudió el desempeño de la CNN cuando se procesan señales radar que poseen un ancho de clutter teórico σ_{t_2} diferente al utilizado para generar los datos de entrenamiento σ_{t_1} . De los resultados se concluyó que la estimación de potencia resulta insesgada si σ_{t_2} se encuentra próximo a σ_{t_1} , sin embargo para las estimaciones de velocidad Doppler media y ancho espectral ambos valores pueden diferir en una cantidad mayor sin afectar considerablemente el resultado final de la estimación.

Para el procesamiento de datos reales utilizando la CNN se tomó el conjunto de datos *staggered* con el que se validó el desempeño de ASPASS. En general, los resultados fueron alentadores y comparables a los obtenidos con los algoritmos DA, SPPP y ASPASS. La CNN demostró su capacidad de procesar datos reales tanto en presencia como en ausencia de clutter terrestre, cumpliendo satisfactoriamente el propósito para el cual fue diseñada. Además en las estimaciones de velocidad Doppler media y ancho espectral se obtuvieron resultados más homogéneos en las regiones analizadas que para los algoritmos DA, SPPP y ASPASS, lo cual es un resultado deseado dada las características del tipo de tormenta meteorológica analizada.

En general, no es conveniente aplicar los filtros de clutter terrestre en cualquier circunstancia. Aún cuando los algoritmos de filtrado sean adaptivos y reconstruyan la señal o el espectro del fenómeno meteorológico, su aplicación afecta a la señal innecesariamente cuando no existen contribuciones de clutter presentes. Por este motivo, en radares operativos los algoritmos de filtrado de clutter terrestre son precedidos por una etapa encargada de identificar su presencia, de modo que solo se aplique el filtro en esa situación. Por ejemplo, de los algoritmos estudiados en esta tesis GMAP, GMAP-TD y ASPASS requieren de una etapa previa para detectar la presencia de clutter terrestre.

Con esta motivación, se diseñó un algoritmo de clasificación de la composición de la señal radar empleando redes neuronales. Una de sus ventajas es que además de detectar la presencia de *clutter + ruido* o de *fenómeno + ruido*, también es capaz de clasificar *clutter + fenómeno + ruido* y solo *ruido*. A diferencia de lo que se hizo para la estimación de momentos espectrales, en esta oportunidad se utilizó una red neuronal con cuatro clases o neuronas en la capa de salida, donde cada clase se corresponde a una de las composiciones de señal antes mencionadas. Sin embargo, mantiene como insumo de entrada la DEP de la señal radar meteorológico para realizar la clasificación, explotando como en el caso anterior la estructura bien definida que presenta. Además, los datos de entrenamiento y validación también se generaron de forma sintética, abarcando un gran número de configuraciones meteorológicas posibles de las diferentes composiciones de la señal.

El método se implementó para el modo convencional de operación del radar y para

el modo de operación *staggered 2/3*. Para ambos se utilizó una estructura de red neuronal convolucional de una dimensión como modelo de machine learning. Las mismas se entrenaron usando datos sintéticos y se estudiaron sus desempeños mediante simulaciones numéricas de tipo Monte Carlo, y mediante la clasificación de datos reales. Para las simulaciones numéricas, en ambas oportunidades se llevaron a cabo varios experimentos con el objetivo de analizar la tasa de acierto y de error que presentan las redes entrenadas en situaciones de interés. Se observó que en general, el desempeño es bueno para ambos modos de operación, y que el mismo se degrada en situaciones en las cuales se dificulta la identificación de las diferentes contribuciones de la señal meteorológica debido a que aparecen enmascaradas en la DEP, como ser: valores bajos de SNR, velocidades Doppler medias del fenómeno cercanas a cero en el modo convencional o cercanas a las correspondientes réplicas del clutter en el modo operación *staggered*, valores grandes o pequeños de ancho espectral del fenómeno y valores bajos de CSR. Quitando esas situaciones límites, el método demostró tener tasas de acierto mayores al 90 % e inclusive del 100 %.

Por otro lado, se validó el desempeño de las CNNs para cada modo de operación empleando mediciones reales de radar. Para el modo de operación convencional se utilizaron datos de los radares RMA-11 y RMA-12. Por su parte, para el modo de operación *staggered 2/3* se emplearon datos del radar RMA-12. En ambos modos de operación, las redes mostraron una alta capacidad para clasificar correctamente la composición de señal con los datos empleados. Los resultados obtenidos fueron corroborados con los PPI de la reflectividad y de la velocidad Doppler media para cada situación. Además, se verificó el efecto de obstrucción de la señal debida al fenómeno ante la presencia del clutter en aquellas regiones donde este último es muy intenso, que se observó durante el estudio de ASPASS. En esas zonas, la red solo detectó la presencia de clutter y ruido.

Por otro lado, dado que el uso de redes neuronales permite el procesamiento de grandes volúmenes de datos en simultáneo, y dependiendo de la memoria de la GPU, inclusive podría procesar cada barrido completo, entonces sería interesante analizar, para diferentes arquitecturas de GPU, si los tiempos involucrados en el procesamiento se ajustan a los requerimientos de las aplicaciones en tiempo real y, en caso de ser necesario, optar por una arquitectura que sin reducir el desempeño significativamente permita optimizar los tiempos de ejecución.

Es importante destacar el potencial, para aplicaciones futuras, que presenta la metodología introducida en esta tesis respecto del uso de machine learning, en particular redes neuronales, para resolver diversos problemas del procesamiento de la señal radar Doppler meteorológico. La misma presenta la flexibilidad de incluir nuevos modelos matemáticos durante la generación de datos sintéticos, los cuales de forma conjunta puedan ajustarse de mejor manera a situaciones reales o que incluyan otros efectos que no fueron considerados, como ser la interferencia WiFi [90], el clutter eólico (refle-

xiones de la señal transmitida por el radar sobre las aspas de los molinos generadores de energía eólica) [49, 50], clutter biológico (reflexiones de la señal transmitida por el radar sobre bandadas de pájaros o de insectos) [51]. Siendo una ventaja sobre métodos como GMAP o GMAP-TD que se basan en un único modelo matemático para la DEP de la la señal y que sólo admiten contribuciones de fenómeno meteorológico, clutter terrestre y ruido y no funcionan correctamente frente a una composición diferente de la señal. Por otro lado, con las redes entrenadas de forma sintética cabe la posibilidad de aplicar *transfer learning* [89] utilizando mediciones reales de radar, para de esta forma tener modelos de machine learning que puedan recoger las particularidades de las señales en escenarios reales, esperando que produzcan mejoras sobre los resultados presentados.

Otra línea futura consiste en recuperar la idea de GMAP-NU, reemplazando el método de reconstrucción de la señal. En lugar de extrapolar el valor de las muestras en el tiempo en una grilla uniforme, teniendo en cuenta como opera GMAP, solo basta con reconstruir el módulo del espectro de señal medida en una grilla uniforme de frecuencias. Para ello, se pueden emplear el tipo de ideas que utiliza el método de estimación de velocidad presentado en [34], en el que se considera que la secuencia muestreada no uniformemente, es el producto de una secuencia que posee espaciado uniforme por una secuencia que contiene unos en las posiciones con muestras disponibles y ceros en la posiciones de muestras no adquiridas. Esto permite escribir el espectro como la convolución de la transformada de Fourier de ambas secuencias, lo que se puede escribir como un sistema de ecuaciones que en general no es invertible, a excepción de evaluar sólo el módulo y se satisfaga que el fenómeno meteorológico no posea un ancho espectral excesivamente grande.

Por otro lado, con el objetivo de mejorar la estimación de velocidad Doppler media en presencia de clutter terrestre, se prevé utilizar de forma iterativa el algoritmo MPP [30] a la salida de un filtro de clutter. Esto permitiría mejorar las estimaciones, principalmente, para escenarios con valores bajos de SNR.

Finalmente, esta tesis se concentró en el procesamiento Doppler, pero es importante considerar la polarimetría de la señal. Por este motivo, se tiene contemplado utilizar las señales de ambos canales polarimétricos para realizar las estimaciones, no solo de los momentos espectrales, sino de las variables polarimétricas [3]. Explotar la información polarimétrica permite mejorar el procesamiento Doppler y es de utilidad en la clasificación de la señales adquiridas. En este aspecto, se está trabajando en la extensión del método ASPASS para que utilice las dos polarizaciones recibidas. Por otro lado, en relación a la clasificación de la composición de la señal radar, se pueden incluir tanto las DEPs de ambos canales como las distintas variables polarimétricas como entrada a la red neuronal. Para ello, en línea con el enfoque presentado, como primer paso es necesario estudiar las distribuciones de probabilidad de las variables polarimétricas en

función de cada composición e implementar modelos de los datos sintéticos con sus características [91].

Apéndice A

Amplitudes de las réplicas

En este apéndice se demuestra la relación que existe entre las amplitudes de las réplicas de la DEP de una secuencia de datos resultante adquirida en modo *staggered* 2/3 e interpolada con ceros.

Sea $y(n) = V(n)p(n)w(n)$ la secuencia discreta en tiempo lento interpolada con ceros, es decir que la separación temporal de sus muestras es uniforme con un período de muestreo $T_u = T_2 - T_1$. La secuencia $y(n)$ se puede pensar que es el resultado de multiplicar a una secuencia de datos “completa” de muestras IQ para un determinado rango, representada por $V(n)$, cuya separación temporal entre muestras es uniforme cada T_u , por una secuencia $p(n) = [10100101001\dots]$, donde los unos se encuentran en las posiciones de las muestras $V(n)$ con las que realmente se cuentan y los ceros corresponden a las posiciones de las muestras “pérdidas” ($p(n)$ en este caso está definida para la relación 2/3). En la definición de $y(n)$ también se incluye la ventana $w(n)$ que se utiliza en la estimación de la DEP.

La DEP de $y(n)$ usando periodograma se aproxima como,

$$S_{yy}(k) = \frac{1}{N} |Y(k)|^2; \quad 0 \leq k \leq N, \quad (\text{A.1})$$

donde $Y(k)$ es la DFT de $y(n)$ y N es la longitud de la secuencia.

Haciendo uso de la propiedad del producto de convolución de la DFT [46], la ecuación (A.1) se puede escribir de la siguiente forma,

$$S_{yy}(k) = S_{VV}(k) \otimes S_{ww}(k) \otimes S_{pp}(k); \quad 0 \leq k \leq N, \quad (\text{A.2})$$

donde \otimes denota la operación convolución circular, $S_{VV}(k)$ es la DEP de $V(n)$, y $S_{ww}(k)$ y $S_{pp}(k)$ son las densidades espectrales de energías de $w(n)$ y $p(n)$, respectivamente, las cuales están dadas por $S_{ww}(k) = |W(k)|^2$ y $S_{pp}(k) = |P(k)|^2$, siendo $W(k)$ y $P(k)$ las DFTs de $w(n)$ y $p(n)$, respectivamente.

La primera convolución de la ecuación (A.2) produce principalmente el ensancha-

miento de la DEP de la señal $V(n)$ y la segunda convolución es la responsable de la aparición de las réplicas en el espectro. Notar que la secuencia $p(n)$ es la repetición de N_r veces de la señal $p_1(n) = [10100]$. Por su parte $P(k) = N_r P_1(k)^{\uparrow N_r}$, donde el operador $\uparrow N_r$ indica sobremuestrear en un factor N_r , es decir, insertar $N_r - 1$ ceros entre las muestras de la secuencia sobre la que opera, en este caso $P_1(k)$ la DFT de $p_1(n)$.

La secuencia $p_1(n)$ posee sólo dos valores distintos de cero, su DFT calculada por definición resulta

$$P_1(k) = 1e^{-j0} + 1e^{-\frac{2\pi k2}{5}} = e^{-j\frac{\pi k2}{5}} \left(e^{j\frac{\pi k2}{5}} + e^{-j\frac{\pi k2}{5}} \right) = 2e^{-j\frac{\pi k2}{5}} \cos\left(\frac{2\pi k}{5}\right). \quad (\text{A.3})$$

Luego, como la convolución de la DEP de la señal ventaneada con $S_{pp}(k)$ hace que aparezcan las réplicas en el espectro, entonces sus amplitudes con respecto a la réplica principal son

$$A_r(k) = \frac{S_{yy}(k)}{S_{yy}(0)} = \frac{|P_1(k)|^2}{|P_1(0)|^2} = \cos^2\left(\frac{2\pi k}{5}\right), \quad k = 0, \dots, 4. \quad (\text{A.4})$$

Es importante destacar que las amplitudes relativas de las réplicas no dependen de la ventana usada.

Bibliografía

- [1] Jackson, J. D. Classical electrodynamics, 1999. [1](#)
- [2] Skolnik, M. I., *et al.* Introduction to radar systems. *New York*, **19621**, 2001. [1](#), [2](#), [3](#), [16](#)
- [3] Doviak, R. J., Zrníc, D. S. Doppler Radar & Weather Observations. Academic Press, 2014. [1](#), [2](#), [4](#), [14](#), [18](#), [19](#), [20](#), [21](#), [22](#), [25](#), [26](#), [27](#), [29](#), [55](#), [67](#), [96](#), [108](#), [112](#), [143](#), [151](#), [156](#), [177](#), [183](#)
- [4] Marcum, J. A statistical theory of target detection by pulsed radar. *IRE Transactions on Information Theory*, **6** (2), 59–267, 1960. [2](#)
- [5] Bringi, V. N., Chandrasekar, V. Polarimetric Doppler weather radar: principles and applications. Cambridge university press, 2001. [2](#), [41](#)
- [6] Richards, M. A. Fundamentals of radar signal processing. McGraw-Hill Education, 2014. [2](#), [3](#), [16](#), [23](#)
- [7] Janssen, L. H., Van Der Spek, G. A. The shape of Doppler spectra from precipitation. *IEEE Transactions on Aerospace and electronic systems*, (2), 208–219, 1985. [2](#), [76](#), [99](#), [122](#), [146](#), [151](#), [173](#)
- [8] Ryzhkov, A. V., Zrníc, D. S. Radar polarimetry for weather observations. Springer, 2019. [3](#), [17](#), [18](#), [19](#), [20](#), [95](#)
- [9] Rodríguez, A. e. SiNaRaMe: Integración de una red de radares hiro-meteorológicos en latinoamérica. *Rev. Fac. Ciencias Exac, Fís. y Nat.*, **4** (1), 41–48, 2017. [3](#)
- [10] de Elía, R., Vidal, L., Lohigorry, P., Mezher, R., Rugna, M. La red argentina de radares meteorológicos de argentina. *Nota Técnica SMN*, **39**, 2017. [3](#)
- [11] Haykin, S. Radar signal processing. *IEEE ASSP Magazine*, **2** (2), 2–18, 1985. [3](#)
- [12] Kelly, E. Performance of an adaptive detection algorithm; rejection of unwanted signals. *IEEE Transactions on Aerospace and Electronic Systems*, **25** (2), 122–133, 1989. [3](#)

- [13] Warde, D. A., Torres, S. Automatic detection and removal of ground clutter contamination on weather radars. En: Proc. 34th Conference on Radar Meteorology. 2009. [3](#)
- [14] Hubbert, J., Dixon, M., Ellis, S. Weather radar ground clutter. part ii: Real-time identification and filtering. *Journal of Atmospheric and Oceanic Technology*, **26** (7), 1181–1197, 2009. [3](#), [5](#), [8](#), [93](#)
- [15] Doviak, R. J., Zrnic, D. S., Sirmans, D. S. Doppler weather radar. *Proceedings of the IEEE*, **67** (11), 1522–1553, 1979. [3](#), [4](#)
- [16] Tahanout, M., Du Châtelet, J. P., *et al.* An improved M-PRT technique for spectral analysis of weather radar observations. *IEEE Transactions on Geoscience and Remote Sensing*, **53** (10), 5572–5582, 2015. [4](#)
- [17] Zrinc, D., Mahapatra, P. Two methods of ambiguity resolution in pulse Doppler weather radars. *IEEE Transactions on Aerospace and Electronic Systems*, (4), 470–483, 1985. [4](#), [7](#), [25](#), [38](#), [39](#), [67](#), [177](#)
- [18] Sirmans, D., Bumgarner, B. Numerical comparison of five mean frequency estimators. *Journal of Applied Meteorology (1962-1982)*, **14** (6), 991–1003, 1975. [4](#)
- [19] Mahapatra, P. R., Zrnic, D. S. Practical algorithms for mean velocity estimation in pulse Doppler weather radars using a small number of samples. *IEEE transactions on geoscience and remote sensing*, (4), 491–501, 1983. [4](#), [5](#)
- [20] Zrnic, D. Spectral moment estimates from correlated pulse pairs. *IEEE Transactions on Aerospace and Electronic Systems*, (4), 344–354, 1977. [5](#)
- [21] Chornoboy, E. S. Optimal mean velocity estimation for Doppler weather radars. *IEEE transactions on geoscience and remote sensing*, **31** (3), 575–586, 1993. [5](#)
- [22] Pinsky, M., i Ventura, J. F., Otto, T., Sterkin, A., Khain, A., Russchenberg, H. W. Application of a simple adaptive estimator for an atmospheric Doppler radar. *IEEE transactions on geoscience and remote sensing*, **49** (1), 115–127, 2010. [5](#)
- [23] Groginsky, H. L., Glover, K. Weather radar canceller design. En: 19th Conference on Radar Meteorology, págs. 192–198. 1980. [5](#)
- [24] Siggia, A., Passarelli, R. Gaussian model adaptive processing (GMAP) for improved ground clutter cancellation and moment calculation. En: Proc. ERAD, tomo 2, págs. 421–424. 2004. [5](#), [29](#), [68](#), [73](#)

- [25] Nguyen, C. M., Chandrasekar, V. Gaussian model adaptive processing in time domain (GMAP-TD) for weather radars. *Journal of Atmospheric and Oceanic Technology*, **30** (11), 2571–2584, 2013. [6](#), [7](#), [34](#), [36](#), [41](#), [42](#), [68](#)
- [26] Torres, S. M., Warde, D. A. Ground clutter mitigation for weather radars using the autocorrelation spectral density. *Journal of Atmospheric and Oceanic Technology*, **31** (10), 2049–2066, 2014. [5](#), [6](#)
- [27] Warde, D. A., Torres, S. M. The autocorrelation spectral density for Doppler-weather-radar signal analysis. *IEEE transactions on geoscience and remote sensing*, **52** (1), 508–518, 2013. [6](#)
- [28] Nguyen, C. M., Moisseev, D. N., Chandrasekar, V. A parametric time domain method for spectral moment estimation and clutter mitigation for weather radars. *Journal of Atmospheric and Oceanic Technology*, **25** (1), 83–92, 2008. [6](#)
- [29] Sachidananda, M., Zrnic, D. An improved clutter filtering and spectral moment estimation algorithm for staggered PRT sequences. *Journal of Atmospheric and Oceanic Technology*, **19** (12), 2009–2019, 2002. [7](#), [8](#), [40](#), [75](#)
- [30] Pascual, J. P., Cogo, J., Collado Rosell, A., Areta, J. Multipulse Processing Algorithm for Improving Mean Velocity Estimation in Weather Radar. *IEEE Transactions on Geoscience and Remote Sensing*, 2021. [7](#), [11](#), [135](#), [183](#)
- [31] Moisseev, D. N., Nguyen, C. M., Chandrasekar, V. Clutter suppression for staggered PRT waveforms. *J. Atmos. Oceanic Technol.*, **25** (12), 2209–2218, 2008. [7](#)
- [32] Torres, S. M., Warde, D. A. Staggered-PRT sequences for Doppler weather radars. part i: Spectral analysis using the autocorrelation spectral density. *J. Atmos. Oceanic Technol.*, **34** (1), 51–63, 2017. [7](#)
- [33] Warde, D. A., Torres, S. M. Staggered-PRT sequences for Doppler weather radars. part ii: Ground clutter mitigation on the NEXRAD network using the CLEAN-AP filter. *J. Atmos. Oceanic Technol.*, **34** (3), 703–716, 2017. [7](#)
- [34] Sachidananda, M., Zrnić, D. Clutter filtering and spectral moment estimation for Doppler weather radars using staggered pulse repetition time (PRT). *Journal of Atmospheric and Oceanic Technology*, **17** (3), 323–331, 2000. [7](#), [67](#), [70](#), [183](#)
- [35] Li, Y., Zhang, G., Doviak, R. J. Ground clutter detection using the statistical properties of signals received with a polarimetric radar. *IEEE Transactions on Signal Processing*, **62** (3), 597–606, 2013. [8](#)

- [36] L-Garcia, A. *Probability, Statistics and Random Processes for Electrical Engineering*, 2008. 8, 56
- [37] Golbon-Haghighi, M.-H., Zhang, G., Li, Y., Doviak, R. J. Detection of ground clutter from weather radar using a dual-polarization and dual-scan method. *Atmosphere*, **7** (6), 83, 2016. 8
- [38] Golbon-Haghighi, M.-H., Zhang, G., Doviak, R. J. Ground clutter detection for weather radar using phase fluctuation index. *IEEE Transactions on Geoscience and Remote Sensing*, **57** (5), 2889–2895, 2018. 8
- [39] Collado Rosell, A. C., Pascual, J. P., Areta, J. Spectrum width correction for clutter mitigation in weather radar. En: 2019 XVIII Workshop on Information Processing and Control (RPIC), págs. 135–139. IEEE, 2019. 9, 53
- [40] Collado Rosell, A., Areta, J., Pascual, J. Ground clutter filtering for weather radar using staggered pulse repetition time. En: 2018 IEEE Biennial Congress of Argentina (ARGENCON), págs. 1–6. IEEE, 2018. 9, 54
- [41] Collado Rosell, A., Pascual, J. P., Areta, J. Adaptive spectral processing algorithm for staggered signals in weather radars. *IET Radar, Sonar & Navigation*, **14** (11), 1659–1670, 2020. 9, 68
- [42] Collado Rosell, A., Cogo, J., Areta, J. A., Pascual, J. P. Doppler processing in weather radar using deep learning. *IET Signal Processing*, **14** (9), 672–682, 2020. 10, 96
- [43] Meikle, H. *Modern radar systems*. Artech House, 2008. 13
- [44] Ali, B. S. *Aircraft Surveillance Systems: Radar Limitations and the Advent of the Automatic Dependent Surveillance Broadcast*. Routledge, 2017. 13
- [45] Moreira, A., Prats-Iraola, P., Younis, M., Krieger, G., Hajnsek, I., Papathanassiou, K. P. A tutorial on synthetic aperture radar. *IEEE Geoscience and remote sensing magazine*, **1** (1), 6–43, 2013. 13
- [46] Papoulis, A., Unnikrishna, S. P. *Probability, random variables and stochastic processes*. McGraw-Hill, 2002. 19, 26, 55, 56, 185
- [47] Dutta, A., Chandrasekar, V. Detection, Analysis and Mitigation of Sea Clutter in Polarimetric Weather Radar. En: 2019 United States National Committee of URSI National Radio Science Meeting (USNC-URSI NRSM), págs. 1–2. 2019. 22

- [48] Hailong, W., Shouyuan, D., Xu, W., Zhao, S. Sea Clutter Recognition Based on Dual-Polarization Weather Radar. En: 2019 International Conference on Meteorology Observations (ICMO). 2019. [22](#)
- [49] Uysal, F., Selesnick, I., Isom, B. M. Mitigation of Wind Turbine Clutter for Weather Radar by Signal Separation. *IEEE Transactions on Geoscience and Remote Sensing*, **54** (5), 2925–2934, 2016. [22](#), [183](#)
- [50] Hood, K., Torres, S., Palmer, R. Automatic Detection of Wind Turbine Clutter for Weather Radars. *Journal of Atmospheric and Oceanic Technology*, **27** (11), 1868–1880, 11 2010. [22](#), [183](#)
- [51] Radhakrishna, B., Fabry, F., Kilambi, A. Fuzzy Logic Algorithms to Identify Birds, Precipitation, and Ground Clutter in S-Band Radar Data Using Polarimetric and Nonpolarimetric Variables. *Journal of Atmospheric and Oceanic Technology*, **36** (12), 2401–2414, 12 2019. [22](#), [183](#)
- [52] Porat, B. A course in digital signal processing. Wiley, 1997. [24](#), [54](#), [70](#), [73](#), [84](#), [86](#)
- [53] Welch, P. The use of fast fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms. *IEEE Transactions on audio and electroacoustics*, **15** (2), 70–73, 1967. [30](#), [70](#)
- [54] Hildebrand, P. H., Sekhon, R. Objective determination of the noise level in Doppler spectra. *Journal of Applied Meteorology*, **13** (7), 808–811, 1974. [30](#), [75](#), [80](#)
- [55] Cho, J. Y., Chornoboy, E. S. Multi-PRI signal processing for the terminal Doppler weather radar. part i: Clutter filtering. *Journal of Atmospheric and Oceanic Technology*, **22** (5), 575–582, 2005. [42](#)
- [56] Zrníc, D., *et al.* Simulation of weatherlike Doppler spectra and signals. *Journal of Applied Meteorology*, **14** (4), 619–620, 1975. [43](#)
- [57] Mitchell, T. M. Does machine learning really work? *AI magazine*, **18** (3), 11–11, 1997. [44](#)
- [58] Goodfellow, I., Bengio, Y., Courville, A., Bengio, Y. Deep learning, tomo 1. MIT press Cambridge, 2016. [44](#), [45](#), [46](#), [48](#), [49](#), [50](#), [51](#), [95](#)
- [59] Han, J., Moraga, C. The influence of the sigmoid function parameters on the speed of backpropagation learning. En: International Workshop on Artificial Neural Networks, págs. 195–201. Springer, 1995. [47](#)

- [60] Kalman, B. L., Kwasny, S. C. Why tanh: choosing a sigmoidal function. En: [Proceedings 1992] IJCNN International Joint Conference on Neural Networks, tomo 4, págs. 578–581. IEEE, 1992. [47](#)
- [61] Nair, V., Hinton, G. E. Rectified linear units improve restricted boltzmann machines. En: Proce of the 27th interna confe on machi learn (ICML-10), págs. 807–814. 2010. [47](#)
- [62] Dunne, R. A., Campbell, N. A. On the pairing of the softmax activation and cross-entropy penalty functions and the derivation of the softmax activation function. En: Proc. 8th Aust. Conf. on the Neural Networks, Melbourne, tomo 181, pág. 185. Citeseer, 1997. [47](#)
- [63] Zou, F., Shen, L., Jie, Z., Zhang, W., Liu, W. A sufficient condition for convergences of adam and rmsprop. En: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, págs. 11127–11135. 2019. [48](#)
- [64] Kingma, D. P., Ba, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014. [48](#), [102](#)
- [65] Rumelhart, D. E., Durbin, R., Golden, R., Chauvin, Y. Backpropagation: The basic theory. *Backpropagation: Theory, architectures and applications*, págs. 1–34, 1995. [49](#)
- [66] Apostol, T. M. Calculus, Volume 1. John Wiley & Sons, 1991. [49](#)
- [67] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, **15** (1), 1929–1958, 2014. [51](#)
- [68] Ioffe, S., Szegedy, C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. En: International conference on machine learning, págs. 448–456. PMLR, 2015. [51](#)
- [69] Dolev, D., Reischuk, R., Strong, H. R. Early stopping in Byzantine agreement. *Journal of the ACM (JACM)*, **37** (4), 720–741, 1990. [51](#)
- [70] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., *et al.* ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision (IJCV)*, **115** (3), 211–252, 2015. [51](#)
- [71] Ziemer, R. E., Tranter, W. H. Principles of communications. John Wiley & Sons, 2014. [56](#), [57](#)

- [72] Björck, Å. Numerical methods for least squares problems. SIAM, 1996. 58
- [73] Jenq, Y.-C. Perfect reconstruction of digital spectrum from nonuniformly sampled signals. *IEEE Transactions on Instrumentation and Measurement*, **46** (3), 649–652, 1997. 61
- [74] Banjanin, Z. B., Zrnic, D. S. Clutter rejection for Doppler weather radars which use staggered pulses. *IEEE Transactions on Geoscience and Remote Sensing*, **29** (4), 610–620, 1991. 68
- [75] Gregory Meymaris, N. Alternative approaches to staggered PRT clutter filtering. En: 26th Conference on Interactive Information and Processing Systems. 2010. 68
- [76] Saltikoff, E., Cho, J. Y., Tristant, P., Huuskonen, A., Allmon, L., Cook, R., *et al.* The threat to weather radars by wireless technology. *Bulletin of the American Meteorological Society*, **97** (7), 1159–1167, 2016. 88
- [77] Ice, R. L., Rhoton, R., Krause, J., Saxion, D., Boydston, O., Heck, A., *et al.* Automatic clutter mitigation in the WSR-88D, design, evaluation, and implementation. En: 34th Conference on Radar Meteorology, Williamsburg, VA. 2009. 93
- [78] Ivić, I. R., Curtis, C., Torres, S. M. Radial-based noise power estimation for weather radars. *Journal of Atmospheric and Oceanic Technology*, **30** (12), 2737–2753, 2013. 94
- [79] Kononenko, I. Machine learning for medical diagnosis: history, state of the art and perspective. *Artificial Intelligence in medicine*, **23** (1), 89–109, 2001. 95
- [80] Zhang, L., Tan, J., Han, D., Zhu, H. From machine learning to deep learning: progress in machine intelligence for rational drug discovery. *Drug discovery today*, **22** (11), 1680–1685, 2017. 95
- [81] Györfi, L., Ottucsák, G., Walk, H. Machine learning for financial engineering, tomo 8. World Scientific, 2012. 95
- [82] Daily, M., Medasani, S., Behringer, R., Trivedi, M. Self-driving cars. *Computer*, **50** (12), 18–23, 2017. 95
- [83] Islam, T., Rico-Ramirez, M. A., Han, D., Srivastava, P. K. Artificial intelligence techniques for clutter identification with polarimetric radar signatures. *Atmospheric Research*, **109**, 95–113, 2012. 95
- [84] Wang, H., Ran, Y., Deng, Y., Wang, X. Study on deep-learning-based identification of hydrometeors observed by dual polarization Doppler weather radars.

- EURASIP Journal on Wireless Communications and Networking*, **2017** (1), 1–9, 2017. 95
- [85] Li, H., Ren, J., Han, J., Fan, Y. Ground clutter suppression method based on FNN for dual-polarisation weather radar. *The Journal of Engineering*, **2019** (19), 6043–6047, 2019. 95
- [86] Zadeh, L. A. Fuzzy logic. *Computer*, **21** (4), 83–93, 1988. 95
- [87] Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., *et al.* TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems, 2015. URL <https://www.tensorflow.org/>, software available from tensorflow.org. 101, 153
- [88] Chollet, F. Keras, 2015. URL <https://github.com/fchollet/keras>. 101, 153
- [89] Pan, S. J., Yang, Q. A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, **22** (10), 1345–1359, 2009. 123, 183
- [90] Walke, B. H., Mangold, S., Berlemann, L. IEEE 802 wireless systems: protocols, multi-hop mesh/relaying, performance and spectrum coexistence. John Wiley & Sons, 2007. 182
- [91] Galati, G., Pavan, G. Computer simulation of weather radar signals. *Simulation Practice and Theory*, **3** (1), 17–44, 1995. 184

Publicaciones asociadas

1. **Arturo Collado Rosell**, J. Areta y Juan P. Pascual, “Filtrado de clutter terrestre en radar meteorológico con PRF alternadas”, actas de ARGENCON 2018, Reunión Bianual Sección Argentina IEEE, S. M. de Tucumán, Argentina, jun. 2018.
2. **Arturo Collado Rosell**, Juan P. Pascual y J. Areta, “Spectrum Width Correction for Clutter Mitigation in Weather Radar”, actas de la XVIII Reunión de Trabajo en Procesamiento de la Información y Control (RPIC 19), Bahía Blanca, Argentina, sep. 2019.
3. **Arturo Collado Rosell**, J.P Pascual y J. Areta, “ Adaptive Spectral Processing Algorithm for Staggered Signals (ASPASS) in weather radars”, IET Radar, Sonar and Navigation. vol 14, num 11, pag 1659–1670, 2020
4. **Arturo Collado Rosell**, J. Cogo, J. Areta y J.P Pascual, “Doppler processing for weather radar using Deep Learning”, IET Signal Processing, vol 14, num 9, pag 672-682, 2020.
5. J.P Pascual, J. Cogo, **Arturo Collado Rosell** y J. Areta, “Multipulse Processing Algorithm for Improving Mean Velocity Estimation in Weather Radar”, IEEE Transactions on Geoscience and Remote Sensing, DOI: 10.1109/TGRS.2021.3066810, 2021.

Publicaciones en elaboración para ser publicadas en revistas internacionales:

- **Arturo Collado Rosell**, J. Cogo, J. Areta y J.P Pascual, “Doppler processing for staggered signals using CNN in weather radars”.
- **Arturo Collado Rosell**, J. Cogo, J. Areta y J.P Pascual, “Weather radar signal classification using Neural Networks”.

Agradecimientos

Los agradecimientos los voy a dividir en dos grupos. En el primero incluiré a las instituciones, y en el segundo a las personas. Dentro de las instituciones quiero resaltar al Instituto Balseiro (IB) por haber sido mi casa de estudios superiores, tanto de grado, como de postgrados. Estoy muy orgulloso de ser un IB y lo voy a llevar siempre en mi corazón. También quiero enviar un especial agradecimiento a la CNEA por financiar las becas que hacen posible que personas como yo podamos estudiar en la Argentina. Otras instituciones que quiero agradecer por haber contribuido de alguna manera al desarrollo de esta tesis son: Universidad Nacional de Río Negro, INVAP, el Servicio Meteorológico Nacional, el Grupo Radar Córdoba y la Secretaría de Infraestructura y Políticas Hídricas de la Nación.

Dentro de los agradecimientos a las personas me gustaría comenzar con mis directores Juan Pablo Pascual y Javier Areta, de los cuales aprendí mucho, y siento hoy en día que pudimos formar buen equipo de trabajo. También quiero incluir a Jorge Cogo por formar parte de nuestro grupo y ser coautor de varios de los trabajos presentados en el marco de esta tesis.

Muchas Gracias a mis padres y mi hermano, por siempre creer en mí, y por su incondicional amor.

Muchas gracias a mis compañeros del edificio de Ingeniería del IB, lugar que compartimos durante este período.

Un especial agradecimiento a Victoria Pizzano por haberme acompañado durante la primera mitad de esta aventura y por haber sido mi refugio cuando más lo necesitaba.

Por último quiero agradecer a todas las personas que de alguna forma u otra han contribuido a que esta etapa de mi vida profesional llegue a su fin (jurados de la tesis, amistades, etc.).

Hoy siento que he crecido mucho no solo desde el punto de vista técnico o profesional, sino también desde el punto de vista humano. Todos estos años compartidos con diferentes personas se quedarán plasmados en mi corazón y mente por el resto de mis días. Finalizo esta etapa con una gran sonrisa y satisfacción propia.

Gracias a tí, querido lector.

