



FACULTAD DE INGENIERÍA

**REDES NEURONALES ARTIFICIALES APLICADAS A LA
PREDICCIÓN Y ESTIMACIÓN DE LOS PARÁMETROS DEL
OLEAJE.**

MEMORIA PARA OPTAR A TÍTULO PROFESIONAL

INGENIERO CIVIL OCEÁNICO

MARCO PATRICIO MATAMALA CASTRO

OCTUBRE 2012

**UNIVERSIDAD DE VALPARAÍSO
FACULTAD DE INGENIERÍA
INGENIERÍA CIVIL OCEÁNICA
CAMPUS SANTIAGO, CHILE**

**“REDES NEURONALES ARTIFICIALES APLICADAS A LA PREDICCIÓN Y
ESTIMACIÓN DE LOS PARÁMETROS DEL OLEAJE.”**

MARCO PATRICIO MATAMALA CASTRO

COMISIÓN REVISORA

NOTA

FIRMA

Luis Zamorano Riquelme

Profesor guía

Mauricio Reyes Gallardo

Docente

José Beyá Marshall

Docente

DECLARACIÓN

Este trabajo, o alguna de sus partes, no ha sido presentado anteriormente en la Universidad de Valparaíso, institución universitaria chilena o extranjera u organismo de carácter estatal, para evaluación, comercialización u otros propósitos. Salvo las referencias citadas en el texto, confirmo que el contenido intelectual de este Proyecto de Título es resultado exclusivamente de mis esfuerzos personales.

La Universidad de Valparaíso reconoce expresamente la propiedad intelectual del autor sobre esta Memoria de Titulación. Sin embargo, en caso de ser sometida a evaluación para los propósitos de obtención del Título Profesional de Ingeniero Civil Oceánico, el autor renuncia a los derechos legales sobre la misma y los cede a la Universidad de Valparaíso, la que estará facultada para utilizarla con fines exclusivamente académicos.

Marco Matamala Castro

Tesista

Luis Zamorano Riquelme

Profesor guía

*Dedico este trabajo a mí querida familia, mi clan,
a mis padres y a mi hermana, que siempre tuvieron una
palabra optimista y un pie de apoyo en los momentos
difíciles, para ellos va este humilde logro,
que sin ellos poco hubiera logrado.*

*También y a modo de homenaje a mis queridos
que no alcanzaron a ver realizado este que ya
dejó de ser un sueño. Pero sé que estarán
viendo desde el palco mi felicidad.
Para ustedes Tata, Tita y Tela.*

*Por último pero no menos importantes a mis abuelo
Maternos, quienes con su apoyo y preocupación
me alentaron en esta verdadera maratón de conocimientos.*

Quiero agradecer por su apoyo y buena disposición para la realización de esta investigación a Luis Zamorano Riquelme quien sirvió de profesor tutor para el desarrollo de la tesis.

También agradecer a Ignacio Beyá y a Catalina Tejo por compartir sus puntos de vistas en largas jornadas de debate acerca de los resultados y en la redacción de la tesis.

A Reinaldo Barriga por facilitar amablemente su código de visualización de espectro en coordenadas polares.

Al Instituto Nacional de Hidráulica quien me acogió como uno más de sus integrantes en este periodo.

A mis amigos Jaime Zapata, Felipe Cáceres e Isabel Vicencio por siempre estar presentes.

*“Mientras los amaneceres sean gratis
y poseas pasión en tu ser,
tendrás la oportunidad de mejorar día a día.
Siéntete dichoso de saber que no tienes
límites para tu crecimiento... “*

Marco M. C.

LISTA DE CONTENIDOS

1	INTRODUCCIÓN.....	1
2	MARCO TEÓRICO	2
2.1	TEORÍA DEL OLEAJE.....	2
2.2	DISPOSITIVOS DE MEDICIÓN DEL OLEAJE	6
2.3	CONSTRUCCIÓN ESPECTROS SINTÉTICOS: JONSWAP	7
2.4	PROCESOS FÍSICOS DE TRANSFORMACIÓN DEBIDO A LA PROPAGACIÓN DEL OLEAJE	10
2.4.1	LAS PRINCIPALES PERTURBACIONES QUE SUFRE EL OLEAJE EN SU PROPAGACIÓN.....	11
2.5	REDES NEURONALES.....	12
2.5.1	EL MODELO BIOLÓGICO.....	12
2.5.2	MODELO DE NEURONA ARTIFICIAL	13
2.5.3	TERMINOLOGÍA UTILIZADA PARA EL DESARROLLO DE UNA RNA	15
2.5.4	METODOLOGÍA DE ENTRENAMIENTO DE UNA RNA.....	18
2.5.5	MÉTODO DE ENTRENAMIENTO GRADIENTE DESCENDENTE	18
2.5.6	MÉTODO DE ENTRENAMIENTO BACKPROPAGATION.....	18
2.5.7	GENERALIZACIÓN.....	23
2.6	MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA)	25
2.7	ÍNDICE DE AJUSTE PARA MODELACIONES MATEMÁTICAS	28
3	OBJETIVOS	29
3.1	MOTIVACIÓN.....	29
3.2	OBJETIVOS GENERALES.....	29
3.3	OBJETIVOS ESPECÍFICOS.....	29
4	ALCANCES	30
5	HIPÓTESIS	31
6	METODOLOGÍA.....	32
7	RESEÑA DEL PROYECTO	36
8	ANTECEDENTES DE LAS APLICACIONES DE LAS RNA AL ESTUDIO MARÍTIMO-OCEANOGRÁFICO.....	39
9	CASOS ESTUDIADOS.....	43

9.1	CASO 1: POST-PROCESO ADCP Y TRANSFERENCIA DE OLEAJE ENTRE BOYA TRIAXYS Y ADCP, LEBU VIII REGIÓN.	43
9.1.1	RESEÑA DEL CASO	43
9.1.2	PROCESO Y SENSIBILIDAD DE LOS DATOS DISPONIBLES EN ADCP.	44
9.1.3	SET DE DATOS DISPONIBLE PARA MODELAR CON RNA.....	48
9.1.4	RESULTADOS POST-PROCESO NEURONAL	50
9.1.5	ENTRENAMIENTO DE RNA INCORPORANDO RETARDO DE LA OLA ENTRE INSTRUMENTOS (T-1)	53
9.1.6	RESULTADO MÉTODO PREDICTIVO ARIMA	63
9.1.7	COMENTARIOS Y CONCLUSIONES	67
9.2	CASO 2: HERRAMIENTA RNA QUE BUSCA MEJORAR LOS PARÁMETROS OBTENIDOS DE NOAA (WAVEWATCH III) A VALORES MEDIDOS IN-SITU.	68
9.2.1	RESEÑA DEL CASO	68
9.2.2	PROCEDIMIENTO	69
9.2.3	RESULTADOS	70
9.2.4	RESULTADO CON MÉTODO PREDICTIVO ARIMA	82
9.2.5	COMENTARIOS Y CONCLUSIONES	86
9.3	CASO 3: HERRAMIENTA DE CONSTRUCCIÓN DE ESPECTROS SINTÉTICOS POR MEDIO DE RNA	87
9.3.1	RESEÑA DEL CASO	87
9.3.2	PROCEDIMIENTO DE ENTRENAMIENTO	88
9.3.3	METODOLOGÍA DEL ENTRENAMIENTO NEURONAL	89
9.3.4	RESULTADOS	90
9.3.5	COMPARACIÓN CON ESPECTRO SINTÉTICO JONSWAP	99
9.3.6	COMENTARIOS Y CONCLUSIONES	100
10	CONCLUSIONES Y COMENTARIOS FINALES	101
11	GLOSARIO	103
12	REFERENCIAS.....	107
13	ANEXOS.....	109
13.1	ANEXO FFT LENGTH (5 ESTADOS DE MAR)	109
13.2	REPRESENTACIÓN EN COORDENADAS POLARES DE ESPECTROS GENERADOS CON RNA.....	113

LISTA DE FIGURAS

Figura 2.1: Esquema de una vista aérea de la superficie libre en un momento determinado. Las líneas de contorno representan 0.2 m; la áreas grises corresponden a depresiones (Holthuijsen, 2007).	2
Figura 2.2: Estructura aleatoria del mar (Pierson, 1955)	3
Figura 2.3: Ejemplo de un perfil de oleaje como superposición de 5 olas sinusoidales; cada una con distinta altura, periodo y fase (Goda Y. , 2000).	4
Figura 2.4: El resultado de transformar un registro de altura de ola en los espectros de amplitud y fase respectivamente (Holthuijsen, 2007).	4
Figura 2.5: Proceso de transformación del espectro de amplitud obtenido mediante la transformada de Fourier en el espectro de densidad de varianza espectral continuo (Holthuijsen, 2007).	6
Figura 2.6: Ejemplo de una medición de oleaje; la elevación de la superficie libre en un punto fijo en función del tiempo (Holthuijsen, 2007).	6
Figura 2.7: Ejemplo de espectro JONSWAP con factor $\gamma=1$ (Goda, 2000).	8
Figura 2.8: El espectro bidimensional o direccional representa la distribución de energía tanto en la frecuencia como en la dirección. En la figura se muestra en coordenadas polares (Holthuijsen, 2007).	8
Figura 2.9: Difracción del oleaje (U.S. Army Coastal Engineering Research Center, 1975)	11
Figura 2.10: Neurona biológica	12
Figura 2.11: Elementos que componen una neurona artificial	13
Figura 2.12: Esquema de una red neuronal artificial (RNA)	16
Figura 2.13: Generalización. Situación idealizada	24
Figura 2.14: Generalización. Situación real	24
Figura 7.1: Energía mareomotriz (parque turbinas SeaGen)	37
Figura 7.2: Energía undimotriz (parque dispositivos Pelamis)	38
Figura 8.1: Casos investigados por S. Mandal 2004 (NRA izquierda espectro PM, derecha datos de campo)	39
Figura 8.2: Topología de RNA utilizada para la obtención de espectro sintético (Reena Naithani, M.C. Deo 2006)	40
Figura 8.3: Testeo para una serie de altura de ola en tiempo real (Londhe & Vijay Panchang, 2006).	41
Figura 8.4: Altura significativa estimada por al a RNA vs la data medida (Bhattacharya et al, 2003)	41
Figura 8.5: a) Input de la data de campo, b) Desnivelaciones alrededor de las Islas de Hawaii. En rojo los resultados obtenidos por la RNA. (Namekar et al, 2009)	42

Figura 9.1: Ubicación de Boya TRYAXIS e Instrumento ADCP, Lebu VIII Región.	43
Figura 9.2: Diferencias entre Hs ADCP y Hs TRIAXYS, resultado para PSpec.....	44
Figura 9.3: Diferencias entre Hs ADCP y Hs TRIAXYS, resultado para VPS.	45
Figura 9.4: Diferencias entre Tp ADCP y Tp TRIAXYS, resultado para PSpec.	45
Figura 9.5: Diferencias entre Tp ADCP y Tp TRIAXYS, resultado para VPS.	46
Figura 9.6: Diferencias entre MWD ADCP y MWD TRIAXYS, resultado para PSpec.....	46
Figura 9.7: Diferencias entre MWD ADCP y MWD TRIAXYS, resultado para VSpec.....	47
Figura 9.8: Diferencias entre Hs ADCP y Hs TRIAXYS, para el set de testeo de la RNA.	48
Figura 9.9: Diferencias entre Tp ADCP y Tp TRIAXYS, para el set de testeo de la RNA.	49
Figura 9.10: Diferencias entre MWD ADCP y MWD TRIAXYS, para el set de testeo de la RNA.....	49
Figura 9.11: Arquitectura utilizada para el entrenamiento de la RNA.	50
Figura 9.12: Diferencias entre el resultado Hs ADCP y Hs RNA.....	51
Figura 9.13: Diferencias entre el resultado Tp ADCP y Tp RNA.....	51
Figura 9.14: Diferencias entre el resultado PWD ADCP y PWD RNA.....	52
Figura 9.15: Diferencias entre el resultado MWD ADCP y MWD RNA.....	52
Figura 9.16: Arquitectura de RNA incorporando retraso de la ola entre instrumentos.....	53
Figura 9.17: Bandas de confianza 95% para testeo de RNA Hs.	54
Figura 9.18: Gráfico del error (residual) para la RNA Hs.....	54
Figura 9.19: Histograma del error Hs (ADCP-RNA).....	55
Figura 9.20: Bandas de confianza 95% para testeo de RNA Tp.	56
Figura 9.21: Gráfico del error (residual) para la RNA Tp.....	56
Figura 9.22: Histograma del error Tp (ADCP-RNA).....	57
Figura 9.23: Bandas de confianza 95% para testeo de RNA PWD.	58
Figura 9.24: Gráfico del error (residual) para la RNA PWD.....	58
Figura 9.25: Histograma del error PWD (ADCP-RNA).....	59
Figura 9.26: Bandas de confianza 95% para testeo de RNA MWD.....	60
Figura 9.27: Gráfico del error (residual) para la RNA MWD.	60
Figura 9.28: Histograma del error MWD (ADCP-RNA).....	61
Figura 9.29: Predicción método ARIMA para Hs (ADCP-Lebu).....	63
Figura 9.30: Predicción método ARIMA para Tp (ADCP-Lebu).....	64
Figura 9.31: Predicción método ARIMA para PWD (ADCP-Lebu).....	65
Figura 9.32: Predicción método ARIMA para MWD (ADCP-Lebu).....	66

Figura 9.33: Zonas de aplicación de los modelos del WaveWatch III (NOAA)	68
Figura 9.34: Arquitectura de RNA para entrenamiento de Hs	71
Figura 9.35: Comparación set de oleaje Watchkeeper (SHOA) y resultado de RNA para Hs.....	72
Figura 9.36: Error o residuo entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para Hs.....	72
Figura 9.37: Histograma del error Hs (Watchkeeper-RNA)	73
Figura 9.38: Bandas de confianza 95% para testeo de RNA Hs (Caso 2).....	73
Figura 9.39: Comparación entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para Tp.....	74
Figura 9.40: Error o residuo entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para Tp.....	74
Figura 9.41: Histograma del error Tp (Watchkeeper-RNA)	75
Figura 9.42: Bandas de confianza 95% para testeo de RNA Tp (Caso 2).....	75
Figura 9.43: Comparación entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para MWD	76
Figura 9.44: Error o residuo entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para MWD.	76
Figura 9.45: Histograma del error MWD (Watchkeeper-RNA).....	77
Figura 9.46: Bandas de confianza 95% para testeo de RNA MWD (Caso 2).	77
Figura 9.47: Comparación entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para PWD.....	78
Figura 9.48: Error o residuo entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para PWD.....	78
Figura 9.49: Histograma del error PWD (Watchkeeper-RNA)	79
Figura 9.50: Bandas de confianza 95% para testeo de RNA PWD (Caso 2).....	79
Figura 9.51: Predicción método ARIMA para Hs (Watchkeeper-Arica)	82
Figura 9.52: Predicción método ARIMA para Tp (Watchkeeper-Arica).....	83
Figura 9.53: Predicción método ARIMA para MWD (Watchkeeper-Arica)	84
Figura 9.54: Predicción método ARIMA para PWD (Watchkeeper-Arica)	85
Figura 9.55: Nodo Extracción de Datos (Zona Central, Chile).....	87
Figura 9.56: Comparación entre un bin medido (bin 355) y otro modelado para 5 años de entrenamiento (Alta energía asociada)	91
Figura 9.57: Comparación entre un bin medido (bin 407) y otro modelado para 5 años de entrenamiento (Alta energía asociada)	91
Figura 9.58: Comparación entre un bin medido (bin 438) y otro modelado para 5 años de entrenamiento (Baja energía asociada)	92

Figura 9.59: Comparación entre un bin medido (bin 287) y otro modelado para 5 años de entrenamiento (Baja energía asociada)	92
Figura 9.60: Comparación entre un bin medido (bin 354) y otro modelado para 1 año de entrenamiento.....	93
Figura 9.61: Comparación entre un bin medido (bin 406) y otro modelado para 1 año de entrenamiento.....	93
Figura 9.62: Comparación entre un bin medido (bin 241) y otro modelado para 1 año de entrenamiento.....	94
Figura 9.63: Comparación entre un bin medido (bin 312) y otro modelado para 1 año de entrenamiento.....	94
Figura 9.64: Comparación entre espectro medido con espectro sintético	95
Figura 9.65: Comparación entre espectro medido con espectro sintético (caso bimodal)	95
Figura 9.66: Comparación entre espectro medido con espectro sintético (caso espectro con mayor energía).....	96
Figura 9.67: Comparación entre espectro medido con espectro sintético (caso bimodal)	96
Figura 9.68: Comparación entre espectro medido con espectro sintético (caso baja correlación).....	97
Figura 9.69: Comparación entre espectro medido con espectro sintético (baja correlación, espectro trimodal).....	98
Figura 9.70: Salida de comparación entre un bin medido (bin293) y otro modelado para 1 año de testeo (Validación cruzada).....	98
Figura 9.71: Salida de comparación entre un bin medido (bin356) y otro modelado para 1 año de testeo (Validación cruzada).....	99
Figura 13.1: Sensibilización de Hs para distintos FFT Length.....	109
Figura 13.2: Sensibilización de Tp para distintos FFT Length.....	110
Figura 13.3: Sensibilización de PWD para distintos FFT Length.....	110
Figura 13.4: Sensibilización de MWD para distintos FFT Length	111
Figura 13.5: Arriba espectro medido y abajo espectro RNA para el 4-12-2006 03:00 (caso 3)	113
Figura 13.6: Arriba espectro medido y abajo espectro RNA para el 30-01-2006 15:00 (caso 3)	114
Figura 13.7: Arriba espectro medido y abajo espectro RNA para el 20-04-2006 12:00 (caso3)	115
Figura 13.8: Arriba espectro medido y abajo espectro RNA para el 24-11-2006 06:00 (caso 3)	116
Figura 13.9: Arriba espectro medido y abajo espectro RNA para el 13-05-2006 06:00 (caso 3)	117

Figura 13.10: Arriba espectro medido y abajo espectro RNA para el 16-06-2006 15:00
(caso3) 118

LISTA DE TABLAS

Tabla 2.1: Funciones de activación..... 15

Tabla 9.1: Coeficientes de correlación para los resultados de procesos de datos ADCP. 47

Tabla 9.2: Resultados del testeo de la RNA..... 53

Tabla 9.3: Resultados de la RNA incorporando retraso de ola entre instrumentos..... 62

Tabla 9.4: Comparación entre resultados con retardo de la ola y resultados sin retardo.. 62

Tabla 9.5: Comparación entre resultados RMA y ARIMA..... 66

Tabla 9.6: Resumen de resultados modelación RNA casos no optimizados. 70

Tabla 9.7: Resumen de resultados modelación RNA casos optimizados. 80

Tabla 9.8: Incremento del índice de ajuste al optimizar cantidad de iteraciones 81

Tabla 9.9: Resumen de resultados para predicciones RNA y ARIMA 86

Tabla 9.10: Resumen de resultados para alternativas realizadas 90

Tabla 13.1: Desviación estándar para 5 estados de mar sensibilizando FF Length 111

Tabla 13.2: Resultados para 5 estados de mar sensibilizando FF Length 112

LISTA DE SÍMBOLOS

OLEAJE		
Símbolo	Descripción	Unidad
α	Amplitud de la ola	m
H	Altura de la ola igual a 2α	m
H_s	Altura significativa de la ola $H/3$	m
ω	Frecuencia angular	rad/s
T	Periodo de la ola	s
T_p	Periodo peak de la ola	s
k	Número de onda	rad/m
L	Longitud de la ola	m
θ	Fase de la ola	rad
f	Frecuencia de la ola $1/T$	$1/s$
$\eta(t)$	Elevación de la superficie en función del tiempo	m
$\underline{\alpha}$	La amplitud tratada como variable aleatoria	m
$E(f_i)$	Símbolo de la densidad de varianza	
$E(f)$	Densidad espectral de frecuencias	$m^2 s$
γ	Agudeza de peak en espectro JONSWAP	
$E(f, \theta)$	Espectro de densidad direccional del oleaje	$m^2 s \cdot \theta$
m_0	Momento espectral de orden cero $\int_0^\infty \int_0^{2\pi} E(f, \theta) df d\theta$	m^2
η_{rms}	Valor medio cuadrático de la superficie libre	m
$H/3$	O llamada H_{m0} es igual a $4.004\eta_{rms} = 4.004\sqrt{m_0}$	m
PWD	Dirección peak del oleaje	θ
MWD	Dirección media del oleaje $\arctan\left(\frac{\int \sin(\theta)E(f, \theta) df d\theta}{\int \cos(\theta)E(f, \theta) df d\theta}\right)$	θ

REDES NEURONALES ARTIFICIALES	
Símbolo	Descripción
α	Taza de aprendizaje
w_{ij}	Peso sináptico entre las neuronas presináptica i y postsináptica j
y_p	Salida obtenida de la red neuronal
d_p	Salida deseada (dato medido)
e_p	Error entre valor deseado y valor obtenido
β	El momento determina el efecto en el instante $t+1$ del cambio de los pesos realizado en el instante t .
x_p	Patrón de entrada
$y_i(t)$	Función de activación de las neuronas
Δw_{ij}	Variación de los pesos sinápticos
$\nabla E(W)$	Gradiente descendiente del error
$h_i(t)$	Regla de propagación esta dada por $\sum_j w_{ij} \cdot x_j(t)$
δ_{pj}	Coefficiente de retropropagación del error para el ajuste de los pesos sinápticos.

MODELO ARIMA	
Símbolo	Descripción
ε_t	Término de error (Innovaciones)
θ_i	Parámetros de las medias móviles
Y_t	Serie temporal de datos
ϕ_0	Parámetros de la autorregresividad
α, β	Parámetros de alisado
p	Autorregresión
d	Integración o Diferenciación
q	Media móvil

RESUMEN

La tesis implementa la aplicación de la teoría de las redes neuronales artificiales a la ingeniería marítima/oceánica con el objetivo de complementar los estudios de caracterización del recurso energético en Chile. Las Redes Neuronales Artificiales (RNA) son modelos matemáticos inspirados en la estructura y funcionamiento de las redes neuronales biológicas, utilizadas principalmente para la predicción y búsqueda de patrones. Por ello utilizando su poder predictivo se definieron tres casos de aplicación puntual para esta investigación, pudiendo existir otros casos de aplicación, a continuación se listan las aplicaciones desarrolladas:

- Se desarrolla una herramienta RNA capaz de transferir los parámetros del oleaje desde la medición de una boya TRIAXYS (INH) (aguas profundas) hasta el dispositivo ADCP (INH) (aguas someras). Para esto se elabora una red que permite, en primera instancia, correlacionar datos tomados entre ambos instrumentos, esto tiene por objetivo, introducir una primera aproximación a una transferencia del oleaje desde aguas profundas (donde se ubica la boya) a la zona de aguas somera en donde se encuentra instalado el instrumento ADCP.
- Se abordan las correlaciones de tipo paramétrica del oleaje, presentado en esta investigación el mejoramiento en el ajuste resultados que presentan los datos provenientes del WaveWatch III (National Oceanic and Atmospheric Administration-NOAA) por medio de parámetros de resumen obtenidos in situ (para este caso, obtenidos de Watchkeeper (Servicio hidrográficos y oceanográfico de la armada-SHOA). Para esto se implementa una red neuronal artificial que permita buscar los mejores ajustes, teniendo como datos de entrada los parámetros de ola de WaveWatch III (NOAA) y como datos ideales (deseado) los de la boya Watchkeeper facilitado por el Servicio Hidrográfico y Oceanográfico de la Armada (SHOA). La idea fundamental es tener una herramienta que permita ajustar los resultados del modelo global WaveWatch III (NOAA) a valores medidos en zonas de mucho interés.
- Por último se elabora una herramienta, que permite la confección de espectros de oleaje sintético direccional con características bimodales (cuando se presente en la realidad) y que mejore el ajuste en la correlación de los espectros medidos a partir de parámetros de resumen de la ola. Además se realiza una comparación con el método de obtención de espectros sintéticos JONSWAP (Hasselmann *et al.*, 1973).

Los resultados presentados tienen una directa relación entre la cantidad de información disponible (datos en series de tiempo, espectral, etc.) y la capacidad de reproducir la realidad o de predicción. Así para una data de 5 años de extensión temporal se obtendrán muy buenos resultados en el ajuste con los datos medido in-situ, pero no así para datas temporales más reducidas (menores a un año) en donde el ajuste a la realidad será pobre. Es por esto que los resultados expuestos en esta tesis varían en el grado de

exactitud con la que reprodujeron la realidad, pues se contaba con distintas extensiones temporales para los distintos casos estudiados, por esto para el último caso de la generación de espectros direccionales se obtuvieron los menores errores RMS respecto a la realidad, ya que se contaba con una extensión temporal de años, en cambio para los casos donde se contaba con sólo meses de extensión en los datos no se obtuvieron significativas disminuciones entre los valores medidos y los estimados por las redes neuronales.

A pesar de esta limitación la investigación cumplió con el objetivo principal de implementar con éxito las RNA al estudio y estimación de los parámetros del oleaje.

1 INTRODUCCIÓN

La energía mecánica (potencial y cinemática) contenida en el oleaje corresponde a la transferencia de la energía del viento, el que a su vez es una transferencia de la energía solar incidente en la atmósfera terrestre. Esta energía incide en el litoral chileno con un comportamiento estocástico y una distribución espacial y temporal que, para un proyecto de producción de energía undimotriz, debe ser conocida y evaluada.

Según lo planteado, para evaluar el recurso energético asociado al oleaje, es necesario conocer su comportamiento en el largo plazo. Para esto existen diversas metodologías que consisten principalmente en propagar el clima de oleaje desde aguas profundas hasta aguas someras, lugar en donde se pueden instalar los dispositivos de extracción de energía undimotriz.

Por lo anterior se hace necesario buscar una metodología que permita incorporar los efectos no lineales propios de los espectros del oleaje, y que por otra parte, el tiempo de cómputo en la obtención del clima de oleaje en aguas someras sea adecuado para las características de un ordenador de escritorio. Para esto se plantea utilizar una metodología basada en algoritmos de la Inteligencia Artificial (IA) conocida como Redes Neuronales Artificiales (RNA), con la se podrá finalmente obtener una correlación más ajustada de los espectros medidos en aguas profundas o someras.

También debido a la necesidad de buscar una alternativa a los métodos tradicionales para la elaboración de espectros sintéticos más precisos a las características que posee el oleaje en las costas chilenas, se considera una RNA con la capacidad de ingresarle parámetros de resumen a fin de crear un espectro de densidad energético.

Las RNA han sido ampliamente utilizadas para problemas donde se requiere encontrar correlaciones de tipo no lineal donde se tiene una considerable cantidad de datos, como por ejemplo: propagación de parámetros de resumen, correlaciones y predicciones en la velocidad del viento, tendencias económicas, entre otras. Aunque en la literatura existen investigaciones de la aplicación de las Redes Neuronales para el área marítima/oceánica, específicamente en la transferencia de parámetros de resumen y estimaciones espectrales del oleaje no direccionales, estas se han concentrado en el hemisferio norte, por lo que nace la necesidad de implementar una metodología útil para las características de las costas chilenas.

2 MARCO TEÓRICO

2.1 TEORÍA DEL OLEAJE

La superficie libre del mar, mirada desde el aire durante un día ventoso, pareciera ser a simple vista completamente aleatoria Figura 2.1. En ella, distinguir olas individuales es casi imposible. La razón es que el mar en ese momento está compuesto de infinitas olas, cada una con diferente altura, periodo, fase y dirección de propagación.




Figura 2.1: Esquema de una vista aérea de la superficie libre en un momento determinado. Las líneas de contorno representan 0.2 m; la áreas grises corresponden a depresiones (Holthuijsen, 2007).

El oleaje en el mar se puede definir de manera teórica como series infinitas de oscilaciones o desnivelaciones provenientes de distintas direcciones, con distintas frecuencias y distintas amplitudes. Para entender bien este concepto, se presenta dicha descripción en la Figura 2.2, (Pierson, 1955).




Figura 2.2: Estructura aleatoria del mar (Pierson, 1955)

Siendo una desnivelación descrita por:

$$\eta(x,t) = \frac{H}{2} \cos(kx - \omega t + \theta)$$

E. 2.1

Con las siguientes variables:

- H = Altura de oleaje = 2α [m]
- α = Amplitud del oleaje [m]
- ω = Frecuencia angular ($\omega = 2\pi/T$) [rad/s]
- T = Periodo de la onda [s]
- k = Número de onda k ($k = 2\pi/L$) [rad/m]
- L = Longitud de la onda [m]
- θ = Fase de la ola [rad]

En la Figura 2.3 es posible observar como las 5 tipos de olas armónicas de distinta altura, periodo y fase, se suman para formar el perfil “aparentemente aleatorio” de abajo. Esto indica que del registro de oleaje también es posible descomponer la elevación de la superficie libre en distintas componentes armónicas, mediante un análisis de Fourier (Stewart, 2002; Percival & Walden, 1993).




Figura 2.3: Ejemplo de un perfil de oleaje como superposición de 5 olas sinusoidales; cada una con distinta altura, periodo y fase (Goda Y. , 2000).

El análisis de Fourier entrega la amplitud y la fase de cada componente f_i (que corresponde al inverso del periodo; i.e. $f = 1/T$), lo que permite armar el espectro de amplitud y el espectro de fase de ese registro (Figura 2.4). El espectro de fase, que tiene valores entre 0 y 2π , se ignorará por ahora ya que se asume que su distribución es uniforme para olas no muy esbeltas (lo cual va a depender entre otros factores de la profundidad y la distancia al punto de generación). El espectro de amplitud por otro lado entrega información importante sobre el estado de mar.




Figura 2.4: El resultado de transformar un registro de altura de ola en los espectros de amplitud y fase respectivamente (Holthuijsen, 2007).

Una vez encontrados los espectros (o asumida una distribución), es posible volver a reproducir la evolución de la superficie libre con una serie de Fourier (E. 2.2), donde $\eta(t)$ es la elevación de la superficie libre en el tiempo y α_0 e θ_i son la amplitud y la fase respectivamente de cada frecuencia f_i . Esta serie, también llamada en este caso “modelo de fase/amplitud aleatoria” es el modelo básico de representación del movimiento de la superficie libre (Holthuijsen, 2007).

La superposición de una serie de desnivelaciones, para un mismo lugar ($x=0$), queda descrita de la siguiente forma:

$$\eta(t) = \alpha_o + \sum_{i=1}^N (\alpha_i \cdot \cos(2\pi \cdot f_i \cdot t + \theta_i)) \quad \text{E. 2.2}$$

En la práctica, el registro de oleaje es cortado en distintos segmentos para obtener así un espectro de amplitud promedio (el valor de $\bar{\alpha}_i$ converge cuando el número de segmentos se incrementa; Stewart, 2002). Además, en vez de la amplitud media $\bar{\alpha}_i$ se prefiere utilizar la varianza de cada componente $1/2 \cdot \underline{\alpha}_i^2$ para construir el espectro. La razón es que: (1) la varianza es estadísticamente más relevante y (2) la varianza es proporcional a la energía de las olas (Holthuijsen, 2007). Finalmente, debido a que en la naturaleza todas las frecuencias están presentes (no solo las f_i seleccionadas), el espectro de varianza es transformado en un espectro de densidad de varianza, donde:

$$E(f_i) = \frac{1}{\Delta f_i} E \left\{ \frac{1}{2} \underline{\alpha}_i^2 \right\} \quad \text{E. 2.3}$$

Notar que $E\{.\}$ representa el valor esperado mientras que $E(.)$ es el símbolo de la densidad de varianza. El guion de $\underline{\alpha}$ indica que la amplitud es tratada como una variable aleatoria.

Un espectro continuo de densidad de varianza espectral también puede ser construido, haciendo:

$$E(f) = \lim_{\Delta f \rightarrow 0} \frac{1}{\Delta f} E \left\{ \frac{1}{2} \underline{\alpha}^2 \right\} \quad \text{E. 2.4}$$

El proceso completo de transformación se puede ver en la Figura 2.5. La función de densidad de varianza espectral, desde ahora llamada simplemente “espectro de frecuencia” o “espectro unidimensional” tiene unidades de $[m^2s]$.

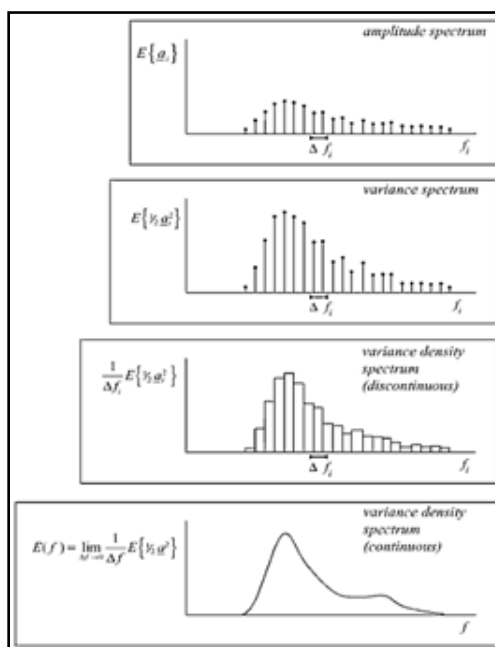


Figura 2.5: Proceso de transformación del espectro de amplitud obtenido mediante la transformada de Fourier en el espectro de densidad de varianza espectral continuo (Holthuijsen, 2007).

2.2 DISPOSITIVOS DE MEDICIÓN DEL OLAJE

Para medir las características del oleaje se recurre a técnicas de medición por instrumentos, los que pueden ser *in situ* (ubicados en el agua; **e.g.** boyas, ADCP y postes¹ de oleaje) o de teledetección² (ubicados sobre el agua; **e.g.** radar, avión, satélite). Cada una tiene sus propias ventajas y limitaciones. El resultado más común de una medición de oleaje es una serie de tiempo con la elevación de la superficie libre en una posición fija horizontal (Holthuijsen, 2007), como la que se observa en la Figura 2.6, o del tipo espectral energético (Figura 2.8).

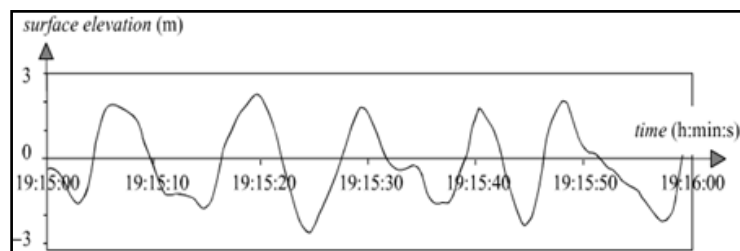


Figura 2.6: Ejemplo de una medición de oleaje; la elevación de la superficie libre en un punto fijo en función del tiempo (Holthuijsen, 2007).

¹ Del inglés wave pole o wave staff

² Del inglés remote-sensing

A partir de este registro es posible identificar las olas individuales, utilizando como técnica estándar los métodos de zero-upcrossing o zero-downcrossing (Goda Y. , 2000), que definen una ola como “el perfil entre dos cruzadas consecutivas de la superficie libre por el cero hacia abajo” (en el caso de zero-downcrossing; donde el cero corresponde al nivel medio del registro). De cada ola es posible obtener luego la altura H_0 (distancia entre el punto más bajo y más alto de ese perfil) y el periodo T_0 (tiempo entre el inicio y el final del perfil). Los registros deben ser cortos para que el estado del mar pueda asumirse estacionario y ergódico pero suficientemente largos para obtener estadística convergente. Idealmente los registros deben tener una extensión de al menos 15 a 30 minutos (Holthuijsen, 2007).

2.3 CONSTRUCCIÓN ESPECTROS SINTÉTICOS: JONSWAP

Distintas formas y parametrizaciones de espectros unidimensionales se han propuesto en base a observaciones en la zona de aguas profundas (zona donde las olas no se ven influenciadas por el fondo marino). La contribución más importante en este sentido viene del ajuste JONSWAP (JOint North Sea WAve Project) (Hasselmann *et al.*, 1973), como resultado, proponen el espectro JONSWAP (Figura 2.7), que puede ser rescrito en forma aproximada en función de la altura significativa de ola $H_{1/3}$, el periodo peak T_p y un factor de forma γ que controla la “agudeza” del peak de la siguiente forma (Goda, 1988) (E. 2.10):

$$E(f) = \beta_j H_{1/3}^2 T_p^{-4} f^{-5} \exp\left[-1.25(T_p f)^{-4}\right] \gamma^{\exp\left[-(T_p f - 1)^2 / 2\sigma^2\right]} \quad \text{E. 2.5}$$

Donde,

$$\beta_j = \frac{0.0624}{0.23 + 0.0336\gamma - 0.185(1.9 + \gamma)^{-1}} [1.094 - 0.01915 \ln \gamma] \quad \text{E. 2.6}$$

$$T_p \cong T_{1/3} / \left[1 - 0.132(\gamma + 0.2)^{-0.559}\right] \quad \text{E. 2.7}$$

$$\sigma = \begin{cases} \sigma_a & : f \leq f_p \\ \sigma_b & : f \geq f_p \end{cases} \quad \text{E. 2.8}$$

$\gamma = 1$ a 7 (media de 3.3), $\sigma_a \cong 0.07$, $\sigma_b \cong 0.09$

El periodo peak T_p se refiere al periodo asociado a la frecuencia de mayor energía en el espectro (**i.e.** $T_p = 1/f_p$; Donde f_p es la frecuencia del peak del espectro tal como se muestra en la Figura 2.7). Es $T_{1/3}$ corresponde al periodo de la ola significativa.

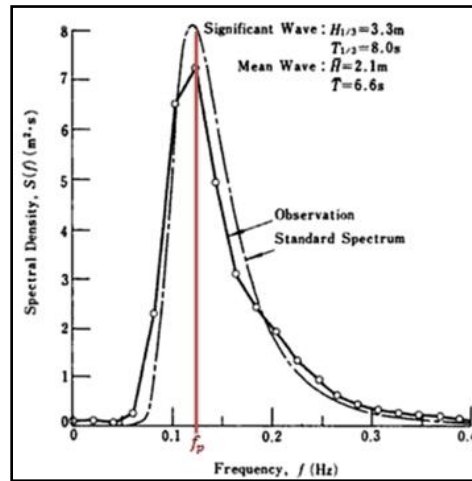


Figura 2.7: Ejemplo de espectro JONSWAP con factor $\gamma=1$ (Goda, 2000).




Figura 2.8: El espectro bidimensional o direccional representa la distribución de energía tanto en la frecuencia como en la dirección. En la figura se muestra en coordenadas polares (Holthuijsen, 2007).

Cuando además del tamaño y el periodo de las olas se toma en cuenta la dirección de estas, el espectro unidimensional $E(f)$ es reemplazado por el espectro bidimensional o direccional $E(f, \theta)$, el cual representa la distribución de la energía no solo en la frecuencia, sino que también en la dirección. Este concepto es introducido ya que en un estado de mar existen muchas componentes viajando en distintas direcciones. El espectro direccional se observa en la Figura 2.8.

El espectro direccional se expresa en la ecuación (E. 2.9) (Goda, 2000):

$$E(f, \theta) = E(f)G(\theta|f) \quad \text{E. 2.9}$$

Donde $G(\theta|f)$ es la función de spreading direccional, la cual se ha encontrado que varía con la frecuencia (Mitsuyasu et al., 1975). La función es normalizada tal que:

$$\int_{-\pi}^{\pi} G(\theta|f) d\theta = 1 \quad \text{E. 2.10}$$

Al igual que con el espectro unidimensional, varias formas han sido propuestas para la función de spreading, sin embargo, aún no se ha establecido una forma estándar para el espectro bidimensional, como sí es el caso del espectro unidimensional (Goda, 2000). Mitsuyasu **et al.**, (1975) proponen la siguiente función basados en mediciones de campo:

$$G(\theta|f) = G_0 \cos^{2s} \left(\frac{\theta}{2} \right) \quad \text{E. 2.11}$$

donde,

$$G_0 = \left[\int_{\theta_{\min}}^{\theta_{\max}} \cos^{2s} \left(\frac{\theta}{2} \right) d\theta \right]^{-1} \quad \text{E. 2.12}$$

Donde θ es la azimuth medida desde la dirección de oleaje principal, y el parámetro “s” corresponde a un parámetro de spreading que se relaciona con la frecuencia de la siguiente manera (Goda & Suzuki, 1975):

$$S = \begin{cases} (f / f_p)^5 s_{\max} & : f \leq f_p \\ (f / f_p)^{-2.5} s_{\max} & : f > f_p \end{cases} \quad \text{E. 2.13}$$

El parámetro s_{\max} fue introducido por Goda & Suzuki (1975) como el principal parámetro para las aplicaciones de ingeniería, y corresponde al valor peak de “s”.

$$s_{\max} = \begin{cases} 10 : \text{Oleaje por viento.} \\ 25 : \text{Swell con distancias cortas de decaimiento.} \\ 75 : \text{Swell con distancias largas de decaimiento.} \end{cases}$$

Si se integra el espectro bidimensional en sus direcciones, se obtiene el espectro unidimensional. Cuando se multiplica el espectro de densidad de varianza por ρg (con ρ siendo la densidad del agua y g la aceleración de gravedad) se obtiene el espectro de densidad de energía (Holthuijsen, 2007).

De los espectros, parámetros estadísticos del oleaje tales como la dirección media, el periodo peak y la altura significativa de ola pueden ser obtenidos. Por ejemplo, para obtener el valor medio cuadrático de la superficie libre η_{rms} , se puede integrar el espectro de densidad de varianza en todas las direcciones y frecuencias para obtener el parámetro m_0 (E. 2.14). Esta integral, que tiene unidad de m^2 , es por definición igual a la varianza de la elevación de la superficie libre, por lo tanto usando la ecuación (E. 2.20) se puede llegar al valor de η_{rms} .

$$m_0 = \int_0^\infty \int_0^{2\pi} E(f, \theta) df d\theta \quad \text{E. 2.14}$$

$$\eta_{rms} = \sqrt{\eta^2} = \sqrt{m_0} \quad \text{E. 2.15}$$

Con el valor de η_{rms} , la altura de ola significativa $H_{1/3}$ puede ser obtenida a través de una proporción confirmada por varias fuentes de observación alrededor del mundo basada en una distribución de Rayleigh para la superficie libre del mar (Goda, 2000), la cual es:

$$H_{1/3} = 4.004\eta_{rms} = 4.004\sqrt{m_0} \quad \text{E. 2.16}$$

Cuando el valor de la altura significativa se obtiene a través del espectro, generalmente se le llama H_{m_0} para diferenciarlo del valor obtenido a través del *zero-crossing method*. Otra notación común para referirse a la altura significativa es H_{sig} , o simplemente H_s .

En el caso del periodo, el parámetro $T_{1/3}$ no se puede obtener directamente del espectro de forma teórica. En cambio, se puede obtener el periodo peak T_p y encontrar una relación con $T_{1/3}$ en base a datos de campo o simulaciones numéricas.

Para hallar la dirección peak del oleaje (*PWD*) es necesario primero identificar el peak de energía del espectro y asociarlo a su dirección correspondiente.

Finalmente, del espectro es posible obtener el valor de la dirección media de las olas, que se define como la dirección normal a las crestas de las olas, mediante la ecuación (E. 2.17).

$$MWD = \arctan \left(\frac{\int \sin(\theta) E(f, \theta) df d\theta}{\int \cos(\theta) E(f, \theta) df d\theta} \right) \quad \text{E. 2.17}$$

2.4 PROCESOS FÍSICOS DE TRANSFORMACIÓN DEBIDO A LA PROPAGACIÓN DEL OLAJE

La transferencia de oleaje consiste en obtener de forma aproximada el oleaje en el sector donde se desea conocer las características del clima de oleaje (generalmente en aguas someras), mediante propagación de las principales características desde aguas profundas hasta el lugar mencionado. Esto se consigue actualmente multiplicando los parámetros característicos del oleaje por funciones de transferencia, las cuales representan el porcentaje de disminución o aumento en la altura de este (coeficientes de agitación), en el sector analizado.

Cuando el oleaje comienza a acercarse a las proximidades de la costa, experimenta una serie de fenómenos que hacen cambiar sus características mecánicas. Siendo los más comunes la refracción, difracción, reflexión, shoaling, entre otros.

2.4.1 LAS PRINCIPALES PERTURBACIONES QUE SUFRE EL OLAJE EN SU PROPAGACIÓN

El asomeramiento, o shoaling es el proceso por el cual la ola aumenta su peralte (relación entre altura de ola y longitud de onda) y disminuye su velocidad de propagación. Es un fenómeno asociado al de refracción.

La refracción se produce como consecuencia de la variación de la celeridad de la onda a lo largo de un mismo frente, en función de la profundidad, la velocidad de las corrientes locales y el periodo. La refracción induce una curvatura en el frente de tal forma que dicho frente tiende a ponerse paralelo a la línea de costa.

La difracción del oleaje es un fenómeno que tiene lugar cuando el frente de onda se encuentra un obstáculo al que rebasa. Tras el obstáculo se produce una zona de sombra en la que, en teoría, el mar debería encontrarse perfectamente en calma (Figura 2.9, izquierda); sin embargo, se produce una transferencia lateral de la energía del oleaje, en la dirección del frente y sentido hacia la zona de sombras (Figura 2.9, derecha). Es lo que se conoce como difracción del oleaje, o expansión lateral (Iribarren & Nogales, 1.954)

La reflexión se produce cuando una onda rebota con algún obstáculo, haciendo que esta perturbe a las demás onda provocando un cambio en la altura normal de la ola.

La ponderación de todos estos efectos antes explicados, crean el coeficiente de agitación, el cual se muestra en la ecuación (E. 2.18):

$$K_{agitación} = K_{shoaling} \cdot K_{refracción} \cdot K_{difracción} \cdot K_{reflección} \quad \text{E. 2.18}$$

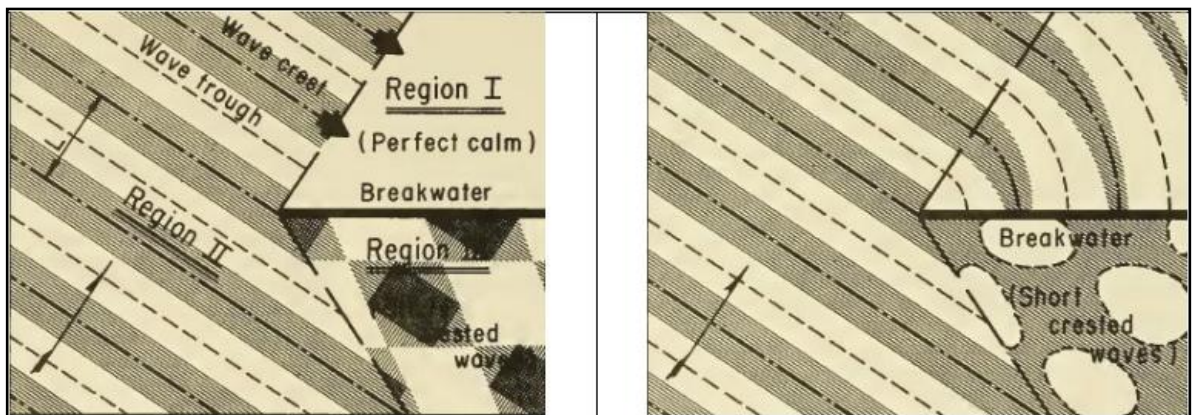


Figura 2.9: Difracción del oleaje (U.S. Army Coastal Engineering Research Center, 1975)

2.5 REDES NEURONALES

Las redes neuronales artificiales (RNA) son modelos matemáticos inspirados en la estructura y funcionamiento de los sistemas nerviosos, donde la neurona es el elemento fundamental. Como todo modelo, realizan una simplificación del sistema real, simulando y tomando las características principales del mismo para la resolución de una tarea determinada.

2.5.1 EL MODELO BIOLÓGICO

El cerebro es el elemento principal del sistema nervioso humano y está compuesto por un tipo especial de célula llamada neurona. Una neurona es una célula viva y como tal posee todos los elementos comunes de las células biológicas. A su vez, las neuronas tienen características propias que les permiten comunicarse entre ellas, lo que las diferencia del resto de las células biológicas. La Figura 2.10 muestra la estructura típica de una neurona biológica.

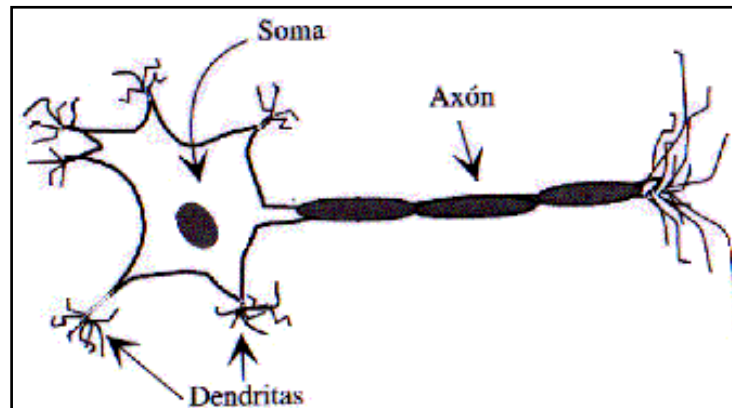


Figura 2.10: Neurona biológica

En la Figura 2.10 se representa una neurona biológica que está compuesta por un cuerpo celular o soma, del cual se desprenden ramificaciones llamadas árbol dendrítico, compuesto por las dendritas. Del soma además comienza una fibra tubular, llamada axón, el cual se ramifica cerca de su extremo. Las dendritas actúan como un canal de entrada de señales provenientes desde el exterior hacia la neurona, mientras que el axón actúa como un canal de salida.

La conexión entre dos neuronas vecinas se denomina sinapsis. En el córtex cerebral (manto de tejido nervioso que cubre la superficie de los hemisferios cerebrales) se observa una organización horizontal en capas, así como también una organización vertical en columnas de neuronas.

La intensidad de una sinapsis no es fija, sino que puede ser modificada en base a la información proveniente del medio. De esta manera la estructura del cerebro no permanece fija sino que se va modificando por la formación de nuevas conexiones, ya

sean excitadoras o inhibitoras, destrucción de conexiones, modificación de la intensidad de la sinapsis, o incluso por muerte neuronal.

La comunicación entre neuronas se lleva a cabo de la siguiente manera: en el soma de las neuronas transmisoras o presinápticas se genera un pulso eléctrico llamado potencial de acción. El pulso eléctrico se propaga a través del axón en dirección a las sinapsis. La información se transmite a las neuronas vecinas utilizando un proceso químico, mediante la liberación de neurotransmisores. Estos a su vez se transmiten a través de la sinapsis hacia la neurona receptora. La neurona receptora o postsináptica toma la señal enviada por cientos de neuronas a través de las dendritas y la transmite al cuerpo celular. Estas señales pueden ser excitadoras (positivas) o inhibitoras (negativas) (Gurney, 1997). El soma es el encargado de integrar la información proveniente de las distintas neuronas. Si la señal resultante supera un determinado umbral (umbral de disparo) el soma emite un pulso que se transmite a lo largo del axón dando lugar a la transmisión eléctrica a lo largo de la neurona. Al llegar la señal al extremo del axón se liberan neurotransmisores que permiten transmitir la señal a las neuronas vecinas. (Nascimento, 1994).

2.5.2 MODELO DE NEURONA ARTIFICIAL

La neurona artificial es un elemento de procesamiento simple que a partir de un vector de entrada produce una salida. En general podemos encontrar tres tipos de neuronas artificiales, donde cada una tiene su contraparte en el sistema nervioso:

1. Las que reciben información directamente desde el exterior, a las cuales se las denomina neuronas de entrada.
2. Las que reciben información desde otras neuronas artificiales, a las cuales se las denomina neuronas ocultas. Es en estas neuronas, en particular en sus sinapsis, donde se realiza la representación de la información almacenada.
3. Las que reciben la información procesada y las devuelven al exterior. A estas neuronas se las denomina neuronas de salida.

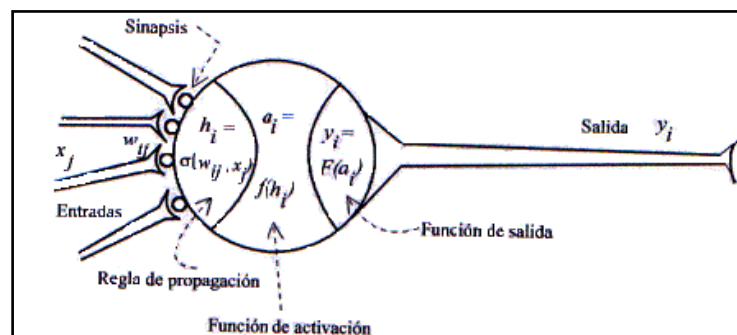


Figura 2.11: Elementos que componen una neurona artificial

Los elementos que componen una RNA serán descritos en los puntos a continuación:

2.5.2.1 ENTRADAS Y SALIDAS

Las entradas y salidas de una neurona pueden ser clasificadas en dos grandes grupos, binarias o continuas. Las neuronas binarias (digitales) sólo admiten dos valores posibles. En general este tipo de neuronas utilizan los siguientes valores $\{0,1\}$ o $\{-1,1\}$. Por su parte, las neuronas continuas (analógicas) admiten valores dentro de un determinado rango, que en general suele definirse como $[0, 1]$ o $[-1, 1]$.

La selección del tipo de neurona a utilizar depende de la aplicación y del modelo a construir.

2.5.2.2 PESOS SINÁPTICOS

El peso sináptico w_{ij} se define como la fuerza de una conexión sináptica entre dos neuronas, la neurona presináptica i y la neurona postsináptica j . Los pesos sinápticos pueden tomar valores positivos, negativos o cero. En caso de una entrada positiva, un peso positivo actúa como excitador, mientras que un peso negativo actúa como inhibidor. En caso de que el peso sea cero, no existe comunicación entre el par de neuronas.

Mediante el ajuste de los pesos sinápticos la red es capaz de adaptarse a cualquier entorno y realizar una determinada tarea.

2.5.2.3 REGLA DE PROPAGACIÓN

Determina el potencial resultante de la interacción de la neurona i con las N neuronas vecinas. El potencial resultante h_i se expresa en la ecuación (E. 2.19):

$$h_i(t) = \sigma_i(w_{ij}, x_j(t)) \quad \text{E. 2.19}$$

La regla de propagación más simple y utilizada consiste en realizar una suma de las entradas ponderadas con sus pesos sinápticos correspondientes:

$$h_i(t) = \sum_j w_{ij} \cdot x_j(t) \quad \text{E. 2.20}$$

2.5.2.4 FUNCIÓN DE ACTIVACIÓN

Determina el estado de activación actual de la neurona en base al potencial resultante h_i y al estado de activación anterior de la neurona $a_i(t-1)$. El estado de activación de la neurona para un determinado instante de tiempo t es expresado de la siguiente manera:

$$a_i(t) = f_i(a_i(t-1), h_i(t)) \quad \text{E. 2.21}$$

Sin embargo, en la mayoría de los modelos se suele ignorar el estado anterior de la neurona, definiéndose el estado de activación en función del potencial resultante h_i :

$$a_i(t) = f_i(h_i(t))$$

E. 2.22

La Tabla 2.1 muestra un listado de las funciones de activación más utilizadas en los distintos modelos de redes neuronales artificiales, con sus respectivos rangos de acción.

Tabla 2.1: Funciones de activación

Función	Fórmula	Rango
Identidad	$y = x$	$[-\infty, \infty]$
Escalón	$y = \begin{cases} +1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$	$[0, 1]$
	$y = \begin{cases} +1 & \text{si } x \geq 0 \\ -1 & \text{si } x < 0 \end{cases}$	$[-1, 1]$
Lineal a tramos	$y = \begin{cases} x & \text{si } -1 \leq x \leq 1 \\ +1 & \text{si } x > 1 \\ -1 & \text{si } x < -1 \end{cases}$	$[-1, 1]$
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$	$[0, 1]$
	$y = \tanh(x)$	$[-1, 1]$
Sinusoidal	$y = \sin(\omega x + \varphi)$	$[-1, 1]$

2.5.2.5 FUNCIÓN DE SALIDA

La función de salida proporciona el valor de salida de la neurona, en base al estado de activación de la neurona. En general se utiliza la función identidad, es decir:

$$y_i(t) = F_i(a_i(t)) = a_i(t)$$

E. 2.23

2.5.3 TERMINOLOGÍA UTILIZADA PARA EL DESARROLLO DE UNA RNA

A continuación se enumerarán los principales términos utilizados en la temática de las Redes neuronales artificiales:

1. ARQUITECTURA DE UNA RED NEURONAL

Una vez definida el tipo de neurona que se utilizará en un modelo de redes neuronales artificiales es necesario definir la topología de la misma. La organización y disposición de las neuronas dentro de una red neuronal se denomina topología, y viene dada por el número de capas, la cantidad de neuronas por capa, el grado de conectividad, y el tipo de conexión entre neuronas.

Las neuronas suelen agruparse en unidades funcionales denominadas capas. Se denomina capa de entrada a aquella que está compuesta por neuronas de entradas y por lo tanto recibe información procedente desde el exterior. Análogamente, se denomina capa oculta y capa de salida a aquellas capas que están compuestas por neuronas ocultas y de salida respectivamente. Una red neuronal artificial está compuesta por una o más capas, las cuales se encuentran interconectadas entre sí. (Véase Figura 2.12)

Entre un par de neuronas de la red neuronal artificial pueden existir conexiones. Estas conexiones son las sinapsis, tienen asociadas un peso sináptico, y son direccionales.

Cuando la conexión se establece entre dos neuronas de una misma capa hablamos de conexiones laterales o conexiones intra-capas. Por el contrario, si la conexión se establece entre neuronas de distintas capas se la denomina conexión inter-capas. Si la conexión se produce en el sentido inverso al de entrada-salida la conexión se denomina recurrente o realimentada.

Una red puede estar formada por una única capa de neuronas. En este caso hablamos de redes mono-capas, y las neuronas que conforman dicha capa cumplen la función de neuronas de entrada y salida simultáneamente. Cuando la red está compuesta por dos o más capas hablamos de redes multicapas.

A su vez, hablamos de redes neuronales con conexión hacia adelante (redes feedforward) cuando las conexiones entre las distintas neuronas de la red siguen un único sentido, desde la entrada de la red hacia la salida de la misma. Cuando las conexiones pueden ser tanto hacia adelante como hacia atrás hablamos de redes recurrentes (redes feedback).




Figura 2.12: Esquema de una red neuronal artificial (RNA)

2. APRENDIZAJE

Durante el proceso de modelación de una red neuronal se pueden distinguir claramente dos fases o modos de operación: la fase de aprendizaje o entrenamiento, y la fase de operación o ejecución.

Durante la primera fase, la fase de aprendizaje, la red es entrenada para realizar un determinado tipo de procesamiento. Una vez alcanzado un nivel de entrenamiento adecuado, se pasa a la fase de operación, donde la red es utilizada para llevar a cabo la tarea para la cual fue entrenada.

3. FASE DE ENTRENAMIENTO

Una vez seleccionada el tipo de neurona artificial que se utilizará en una red neuronal y determinada su topología es necesario entrenarla para que la red pueda ser utilizada. Partiendo de un conjunto de pesos sinápticos aleatorio, el proceso de aprendizaje busca un conjunto de pesos que permitan a la red desarrollar correctamente una determinada tarea. Durante el proceso de aprendizaje se va refinando iterativamente la solución hasta alcanzar un nivel de operación suficientemente bueno.

El proceso de aprendizaje se puede dividir en tres grandes grupos de acuerdo a sus características (Isasi Viñuela & Galván León, 2004), (Yao, 1999):

- Aprendizaje supervisado. Se presenta a la red un conjunto de patrones de entrada junto con la salida esperada. Los pesos se van modificando de manera proporcional al error que se produce entre la salida real de la red y la salida esperada.
- Aprendizaje no supervisado. Se presenta a la red un conjunto de patrones de entrada. No hay información disponible sobre la salida esperada. El proceso de entrenamiento en este caso deberá ajustar sus pesos en base a la correlación existente entre los datos de entrada.
- Aprendizaje por refuerzo. Este tipo de aprendizaje se ubica entre medio de los dos anteriores. Se le presenta a la red un conjunto de patrones de entrada y se le indica a la red si la salida obtenida es o no correcta. Sin embargo, no se le proporciona el valor de la salida esperada. Este tipo de aprendizaje es muy útil en aquellos casos en que se desconoce cuál es la salida exacta que debe proporcionar la red.

4. FASE DE OPERACIÓN

Una vez finalizada la fase de aprendizaje, la red puede ser utilizada para realizar la tarea para la que fue entrenada. Una de las principales ventajas que posee este modelo es que la red aprende la relación existente entre los datos, adquiriendo la capacidad de generalizar conceptos. De esta manera, una red neuronal puede tratar con información que no le fue presentada durante de la fase de entrenamiento.

2.5.4 METODOLOGÍA DE ENTRENAMIENTO DE UNA RNA

En el contexto de las redes neuronales el aprendizaje puede ser visto como el proceso de ajuste de los parámetros libres de la red (Yao, 1995). Partiendo de un conjunto de pesos sinápticos aleatorio, el proceso de aprendizaje busca un conjunto de pesos que permitan a la red desarrollar correctamente una determinada tarea. El proceso de aprendizaje es un proceso iterativo, en el cual se va refinando la solución hasta alcanzar un nivel de operación suficientemente bueno.

La mayoría de los métodos de entrenamiento utilizados en las redes neuronales con conexión hacia delante consisten en proponer una función de error que mida el rendimiento actual de la red en función de los pesos sinápticos. El objetivo del método de entrenamiento es encontrar el conjunto de pesos sinápticos que minimizan (o maximizan) la función. El método de optimización proporciona una regla de actualización de los pesos que en función de los patrones de entrada modifica iterativamente los pesos hasta alcanzar el punto óptimo de la red neuronal.

2.5.5 MÉTODO DE ENTRENAMIENTO GRADIENTE DESCENDENTE

El método de entrenamiento más utilizado es el método del gradiente descendente. Este método define una función $E(W)$ que proporciona el error que comete la red en función del conjunto de pesos sinápticos W . El objetivo del aprendizaje será encontrar la configuración de pesos que corresponda al mínimo global de la función de error, aunque en muchos casos es suficiente encontrar un mínimo local lo suficientemente bueno (Cauwenberghs, 1993).

El principio general del método es el siguiente: dado un conjunto de pesos $W(0)$ para el instante de tiempo $t=0$, se calcula la dirección de máxima variación del error. La dirección de máximo crecimiento de la función $E(W)$ en $W(0)$ viene dado por el gradiente $\nabla E(W)$. Luego, se actualizan los pesos siguiendo el sentido contrario al indicado por el gradiente $\nabla E(W)$, dirección que indica el sentido de máximo decrecimiento (Defalco, 1997)(E. 2.25). De este modo se va produciendo un descenso por la superficie de error hasta alcanzar un mínimo local.

2.5.6 MÉTODO DE ENTRENAMIENTO BACKPROPAGATION

La red Backpropagation fue desarrollada por Rumelthar, Hinton & Williams en 1986, formalizaron un método que permite a la red neuronal aprender la asociación que existe entre los patrones de entrada a la misma y las clases correspondientes, utilizando más niveles de neuronas que el Perceptrón. Este método conocido como propagación del error hacia atrás, está basado en la generalización de la Regla Delta. Es un método de aprendizaje supervisado de gradiente descendente, en el que se distinguen claramente dos fases:

Pasos hacia delante:

1. Selecciona un vector de entrada desde el conjunto de entrenamiento.
2. Aplica esta entrada a la red y calcula la salida.

Pasos hacia atrás:

3. Calcular el error entre la salida calculada y la salida deseada de la entrada usada.
4. Ajustar los pesos para que el error cometido entre la salida calculada y la salida deseada sea disminuido.
5. Repetir los pasos 1 al 4 para todas las entradas del conjunto de entrenamiento, hasta que el error global sea aceptablemente bajo.

2.5.6.1 ALGORITMO DEL MÉTODO BACKPROPAGATION

El algoritmo propone una actualización iterativa de los pesos de la siguiente manera:

$$W(t+1) = W(t) + \nabla W(t) \quad \text{E. 2.24}$$

Si tomamos una variación proporcional al gradiente de una función de error $E(W)$ tenemos que:

$$W(t+1) = W(t) - \alpha \nabla E[W(t)] \quad \text{E. 2.25}$$

Donde α indica el tamaño del paso tomado en cada iteración, pudiendo ser diferente para cada peso e idealmente debería ser infinitesimal. El tamaño del paso es un factor importante a la hora de diseñar un método de estas características. Si se toma un paso muy chico el proceso de entrenamiento resulta muy lento, mientras que si el tamaño del paso es muy grande se producen oscilaciones en torno al punto mínimo.

Como se explicó anteriormente el primer paso de este algoritmo consiste en propagar hacia delante un patrón de entrada x_p y obtener la salida de la red y_p .

La salida de la neurona i viene dada según su estado de activación. Si consideramos la función de salida identidad tenemos que:

$$y_i(t) = F_i(a_i(t)) = a_i(t) \quad \text{E. 2.26}$$

Siendo

$$a_i(t) = f_i(h_i(t)) \quad \text{E. 2.27}$$

La regla de propagación más simple y utilizada consiste en realizar una suma de las entradas ponderadas con sus pesos sinápticos correspondientes.

$$h_i(t) = \sum_j w_{ij} \cdot x_j(t) \quad \text{E. 2.28}$$

Se compara la salida obtenida y_p con la salida deseada d_p , obteniéndose un error que viene dado por

$$e_p = \frac{1}{2} \sum_{k=1}^M (d_{pk} - y_{pk})^2 \quad \text{E. 2.29}$$

donde k es el índice de neurona para las neuronas de la última capa, y M el total de neuronas de la misma.

El error total de la red está dado por:

$$e = \sum_{p=1}^P e_p \quad \text{E. 2.30}$$

siendo p el índice de la muestra, y P el número total de muestras.

De acuerdo a la ecuación (E. 2.25) la variación de los pesos sinápticos será proporcional al gradiente de la función de error:

$$\Delta w_{ij} = -\alpha \frac{\partial e_p}{\partial w_{ij}} \quad \text{E. 2.31}$$

Si aplicamos la regla de la cadena a (E. 2.31) obtenemos que

$$\frac{\partial e_p}{\partial w_{ij}} = \frac{\partial e_p}{\partial h_j} \frac{\partial h_j}{\partial w_{ij}} \quad \text{E. 2.32}$$

La ecuación (E. 2.32) expresa la derivada del error en función de dos derivadas. La derivada del error respecto al potencial resultante h_j indica como varía el error al modificar la entrada de la neurona j , mientras que la derivada con respecto al peso sináptico w_{ji} indica como varía la entrada de la neurona j al cambiar el peso de la conexión que va desde la neurona i hasta la neurona j .

El segundo término de la expresión (E. 2.32) lo podemos expresar a partir de la ecuación (E. 2.39) de la siguiente manera:

$$\frac{\partial h_j}{\partial w_{ij}} = \frac{\partial \sum_i w_{ij} \cdot y_{pi}}{\partial w_{ij}} = y_{pi} \quad \text{E. 2.33}$$

Si escribimos al primer término de la ecuación (E. 2.32) como

$$\frac{\partial e_p}{\partial h_j} = -\delta_{pj} \quad \text{E. 2.34}$$

tenemos que

$$\frac{\partial e_p}{\partial w_{ij}} = -\delta_{pj} \cdot y_{pi} \quad \text{E. 2.35}$$

y por lo tanto la ecuación (E. 2.31) queda expresada de la siguiente manera:

$$\Delta w_{ij} = -\alpha \delta_{pj} \cdot y_{pi} \quad \text{E. 2.36}$$

Para calcular el valor de delta se vuelve a aplicar la regla de la cadena

$$\delta_{pj} = -\frac{\partial e_p}{\partial h_j} = -\left(\frac{\partial e_p}{\partial y_{pj}} \frac{\partial y_{pj}}{\partial h_j} \right) \quad \text{E. 2.37}$$

El cálculo del segundo término de la ecuación (E. 2.37) es simple si observamos las ecuaciones (E. 2.26) y (E. 2.27)

$$\frac{\partial y_{pj}}{\partial h_j} = \frac{\partial f_j(h_j)}{\partial h_j} = f'_j(h_j) \quad \text{E. 2.38}$$

sin embargo, para el cálculo del primer término de la ecuación (E. 2.37) es necesario distinguir entre dos casos diferentes:

1) LA NEURONA J ES UNA NEURONA DE SALIDA

En este caso podemos obtener el segundo término a partir de la ecuación (E. 2.29) ya que el subíndice j es igual al subíndice k

$$\frac{\partial e_p}{\partial y_{pj}} = \frac{\partial \frac{1}{2} \sum_{j=1}^M (d_{pj} - y_{pj})^2}{\partial y_{pj}} = -(d_{pj} - y_{pj}) \quad \text{E. 2.39}$$

Así, la variación de los pesos de una conexión que va hacia la capa externa de la red se calcula como:

$$\Delta w_{ji} = \alpha (d_{pj} - y_{pj}) f'_j(h_j) y_{pi} \quad \text{E. 2.40}$$

2) LA NEURONA J ES UNA NEURONA OCULTA

En este caso es necesario aplicar nuevamente la regla de la cadena

$$\frac{\partial e_p}{\partial y_{pj}} = \sum_k \left(\frac{\partial e_p}{\partial h_k} \frac{\partial h_k}{\partial y_{pj}} \right) \quad \text{E. 2.41}$$

Donde k es el subíndice de las neuronas que pertenecen a la próxima capa. La ecuación (E. 2.42) la podemos reescribir utilizando la ecuación (E. 2.33)

$$\frac{\partial e_p}{\partial y_{pj}} = \sum_k \left(\frac{\partial e_p}{\partial h_k} \frac{\partial \sum_j (w_{kj} y_{pj})}{\partial y_{pj}} \right) = \sum_k \left(\frac{\partial e_p}{\partial h_k} w_{kj} \right) \quad \text{E. 2.42}$$

por la ecuación (E. 2.34) tenemos que

$$\frac{\partial e_p}{\partial y_{pj}} = \sum_k (-\delta_{pk} w_{kj}) = -\sum_k (\delta_{pj} w_{kj}) \quad \text{E. 2.43}$$

Así, la variación de los pesos de una conexión que va desde una capa hacia otra capa de la red que no sea la externa se calcula como:

$$\Delta w_{ji} = \alpha \sum_k (\delta_{pk} w_{kj}) \cdot f'_j(h_j) y_{pi} \quad \text{E. 2.44}$$

Se incorpora una amplitud de paso que viene dado por la tasa de aprendizaje (α). A mayor tasa de aprendizaje el proceso será más rápido. Sin embargo, si la tasa de aprendizaje es muy alta puede dar lugar a oscilaciones en torno a un mínimo local, o también nunca converger en un valor estable. Es posible disminuir el impacto de dichas oscilaciones mediante la adición de un momento (β), quedando la expresión de la siguiente manera (E. 2.36):

$$\Delta w_{ji}(t+1) = \alpha \delta_{pj} w_{pi} + \beta \Delta w_{ji}(t) \quad \text{E. 2.45}$$

De esta manera el momento β determina el efecto en el instante $t+1$ del cambio de los pesos realizado en el instante t .

Con este momento se consigue la convergencia de la red en menor número de iteraciones, ya que si la modificación de los pesos en los instantes t y $t+1$ es en la misma dirección, entonces el descenso por la superficie de error en $t+1$ es mayor. En cambio, si la modificación en los pesos en los instantes t y $t+1$ se produce en direcciones opuestas,

el paso que se da en $t+1$ es más pequeño, lo que es adecuado, ya que esto significa que se ha pasado por un mínimo.

Resumiendo, el algoritmo Backpropagation queda expresado de la siguiente manera:

$$w_{ji}(t+1) = w_{ji}(t) + [\alpha \delta_{pj} y_{pj} + \beta \Delta w_{ji}(t)] \quad \text{E. 2.46}$$

$$\text{Siendo } \delta_{pj} = \begin{cases} (d_{pj} - y_{pj}) f'_j(h_j) & \text{si } j \text{ es una neurona de salida} \\ \sum_k (\delta_{pk} w_{kj}) f'_j(h_j) & \text{si } j \text{ es una neurona oculta} \end{cases}$$

2.5.7 GENERALIZACIÓN

Una vez finalizada la fase de aprendizaje, la red puede ser utilizada para realizar la tarea para la que fue entrenada. Una de las principales ventajas que posee este modelo es que la red aprende la relación existente entre los datos, adquiriendo la capacidad de generalizar conceptos. De esta manera, una red neuronal puede tratar con información que no le fue presentada durante de la fase de entrenamiento (Chinrungrueng, 1988).

Cuando se evalúa una red neuronal no sólo es importante evaluar si la red ha sido capaz de aprender los patrones de entrenamiento. Es imprescindible también evaluar el comportamiento de la red ante patrones nunca antes vistos. Esta característica de las redes neuronales se la conoce como capacidad de generalización y es adquirida durante la fase de entrenamiento (Sanger, 1989).

Es necesario que durante el proceso de aprendizaje la red extraiga las características de las muestras, para poder luego responder correctamente a nuevos patrones.

De lo dicho anteriormente surge la necesidad de evaluar durante la fase de entrenamiento dos tipos de errores. El error de aprendizaje, que indica la calidad de la respuesta de la red a los patrones de entrenamiento, y el error de generalización, que indica la calidad de la respuesta de la red a patrones nunca antes vistos. Para poder obtener una medida de ambos errores es necesario dividir el set de datos disponibles en dos, el set de datos de entrenamiento, y el set de datos de evaluación. El primero se utiliza durante la fase de entrenamiento para que la red pueda extraer las características de los mismos y, mediante el ajuste de sus pesos sinápticos, la red logre una representación interna de la función. El set de evaluación se utiliza para evaluar la capacidad de generalización de la red.

La causa más común de la pérdida de capacidad de generalización es el sobre-aprendizaje. Esto sucede cuando la cantidad de ciclos de entrenamientos tiende a ser muy alta. Se observa que la respuesta de la red a los patrones de entrenamiento es muy buena mientras que la respuesta a nuevos patrones tiende a ser muy pobre. Al aumentar el número de ciclos la red tiende a sobre-ajustar la respuesta a los patrones de

entrenamiento, a expensas de una menor capacidad de generalización. La Figura 2.13 muestra una situación idealizada de lo dicho anteriormente. En la misma se observa que en un determinado punto la red comienza a perder capacidad de generalización como consecuencia del sobre-aprendizaje de los patrones de entrenamiento.

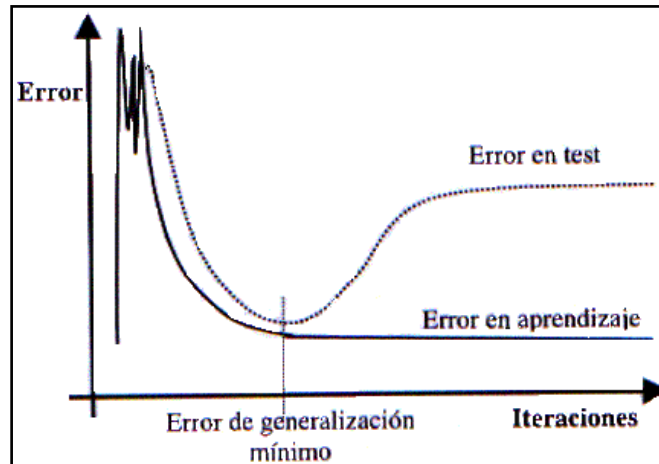


Figura 2.13: Generalización. Situación idealizada

En la Figura 2.14 se muestra una situación más real del mismo caso. A medida que transcurre el proceso de aprendizaje se obtienen varios mínimos sobre el conjunto de evaluación. Existen diversas técnicas de parada temprana (early stopping) aunque en la mayoría de los casos se deja que el proceso de aprendizaje avance hasta alcanzar una cota de error razonable, guardando periódicamente las distintas configuraciones intermedias para luego seleccionar la de menor error de evaluación.




Figura 2.14: Generalización. Situación real

En ocasiones la pérdida de capacidad de generalización se produce por el uso excesivo de neuronas ocultas en la red neuronal. Esto hace que la red tienda a ajustar con mucha exactitud los patrones de entrenamiento, evitando que la red extraiga las características del conjunto. Este problema se ve agravado cuando los patrones de entrenamiento poseen ruido, ya que la red ajusta también el ruido de los mismos.

2.6 MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA)

En estadística y econometría, en particular en series temporales, un modelo autorregresivo integrado de media móvil o ARIMA (acrónimo del inglés autoregressive integrated moving average) es un modelo estadístico que utiliza variaciones y regresiones de datos estadísticos con el fin de encontrar patrones para una predicción hacia el futuro. Este modelo fue desarrollado a finales de los sesenta del siglo pasado. Box & Jenkins (1976) lo sistematizaron.

ARIMA necesita identificar los coeficientes y número de regresiones que se utilizarán. Este modelo es muy sensible a la precisión con que se determinen sus coeficientes.

ARIMA es un modelo (p,d,q) en donde:

p : Autorregresión

d : Integración o Diferenciación

q : Media Móvil

Un modelo ARIMA es un modelo dinámico de series de tiempo, es decir las estimaciones futuras vienen explicadas por los datos del pasado y no por variables independientes. El modelo ARIMA (p,d,q) se puede representar como:

$$Y_t = -(\Delta^d Y_t - Y_t) + \phi_0 + \sum_{i=1}^p \phi_i \Delta^d Y_{t-1} - \sum_{i=1}^q \theta_i \varepsilon_{t-1} + \varepsilon_t \quad \text{E. 2.47}$$

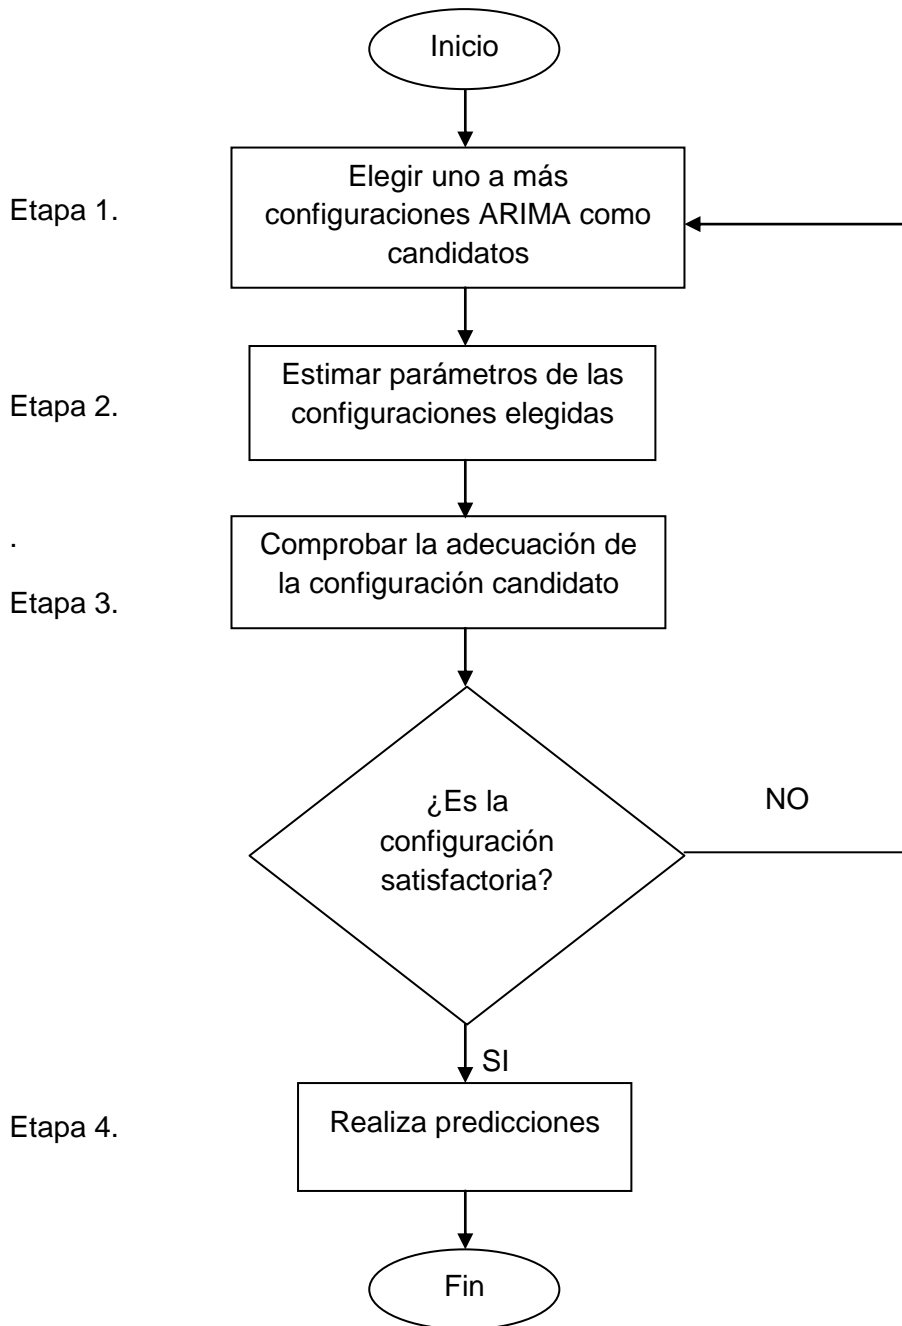
en donde d corresponde a las d diferencias que son necesarias para convertir la serie original en estacionaria, ϕ_1, \dots, ϕ_p son los parámetros pertenecientes a la parte "autorregresiva" del modelo, $\theta_1, \dots, \theta_p$ los parámetros pertenecientes a la parte "medias móviles" del modelo, ϕ_0 es una constante, y ε_t es el término de error (llamados también innovaciones).

Se debe tomar en cuenta que:

$$\Delta Y_t = Y_t - Y_{t-1} \quad \text{E. 2.48}$$

Un modelo SARIMA (Seasonal AutoRegressive Integrated Moving Average) se define como un modelo ARIMA que, además, considera el efecto de la estacionalidad.

Para la ejecución del modelo ARIMA se identifican principalmente 4 etapas que serán descritas a continuación (Maté C., 2011):



Etapa 1.- Identificación

En esta etapa analizamos mediante distintas técnicas cual es el modelo ARIMA (configuración) que, a priori, mejor se puede ajustar a la serie. Según la metodología clásica, las herramientas que permiten identificar el patrón que sigue la serie son las funciones de autocorrelación.

La idea básica para utilizar estas funciones de autocorrelación es la siguiente: cada modelo ARIMA tiene asociadas funciones de autocorrelación teóricas. En esta etapa comparamos las funciones de autocorrelación estimadas con las teóricas y elegimos como modelo tentativo aquel al que más se aproximen ambas. El modelo que obtengamos es, como se ha dicho anteriormente, tentativo y debemos realizar el resto de las etapas para comprobar que realmente es el adecuado.

Etapa 2.- Estimación

En esta etapa obtenemos las estimaciones de los parámetros del modelo ARIMA, una vez hemos fijados en la etapa de identificación los órdenes autorregresivo y de media móvil. Esta estimación se realiza mediante minimización cuadrática del error de ajuste. Esta etapa nos proporciona señales de aviso sobre si el modelo es adecuado o no. En particular, si los coeficientes no cumplen ciertas inecuaciones derivadas de la invertibilidad y la estacionalidad, el modelo ajustado debe ser rechazado.

Etapa 3.- Comprobación

Box y Jenkins proponen algunas comprobaciones de hipótesis que deben ser realizadas para comprobar que el modelo estimado es estadísticamente adecuado. Algunas de las comprobaciones que se deben realizar son que los residuos cumplen las hipótesis de ruido blanco o que no existen coeficientes no significativos.

Una vez hemos comprobado que el modelo es correcto, podemos realizar predicciones usando el mismo.

Para solventar el problema de la identificación mediante comparación de funciones de autocorrelación, hay desarrollos de algoritmos que unen la etapa de identificación y estimación. Así se logra poder orientar el desarrollo del algoritmo a medidas de error y comprobación de hipótesis del modelo. Mediante estos algoritmos podemos ajustar de una manera correcta modelos ARIMA con órdenes altos.

3. Equivalencia de modelos ARIMA con alisados exponenciales

La formulación ARIMA permite incluir algunos de los modelos de alisado exponencial. Sus predicciones son idénticas a las del modelo ARIMA asociado (McKenzie E., 1984),

Las equivalencias más importantes son:

- La predicción de un alisado exponencial simple es equivalente a la de un ARIMA (0,1,1). El parámetro de media móvil θ coincide con $1 - \alpha$, siendo α el parámetro de alisado.
- El método de Holt lineal es equivalente a un modelo ARIMA(0,2,2). Los valores de los parámetros de media móvil serán $\theta_1 = 2 - \alpha - \beta$ y $\theta_2 = \alpha - 1$, siendo α y β los parámetros de alisado.

La gran ventaja de estas equivalencias es que permiten calcular intervalos de predicción mediante los modelos ARIMA. Dado que ningún alisado exponencial es un modelo estadístico, el cálculo de los intervalos de predicción es tarea muy complicada.

De hecho, se dice que los alisados exponenciales dan predicciones punto a punto. Debe quedar claro que estas equivalencias son en el sentido de que las predicciones que generan ambas metodologías son las mismas, pero esto no implica que los modelos que generan esas predicciones sean iguales.

4. Predicción mediante un modelo ARIMA

Para realizar predicciones puntuales mediante un modelo ARIMA, se utiliza la notación algebraica. Se resuelve la ecuación para Y_t . Para ello se introducen las estimaciones de la constante del modelo y de los parámetros φ y θ se asigna cero como valor esperado del error ε_t . Lo que se realiza a continuación es insertar los valores pasados de Y_t y de los errores. En la práctica debemos usar como errores los obtenidos en la etapa de estimación, y si el periodo de predicción es mayor que el orden de media móvil, asignaremos a las estimaciones de los errores el valor nulo. De igual modo utilizaremos las predicciones de Y_t en el caso de que el periodo de predicción sea mayor al orden autorregresivo.

2.7 ÍNDICE DE AJUSTE PARA MODELACIONES MATEMÁTICAS

El índice de ajuste, se utiliza comúnmente para comparar las estimaciones o predicciones de un modelo (P_i , $i = 1, 2, \dots, n$) con respecto a observaciones o mediciones en terreno (O_i , $i = 1, 2, \dots, n$) que se consideran fidedignas (Willmott, 2011). Las unidades de P y O deben ser las mismas. El conjunto de errores de predicción de modelo, por lo general se compone de los ($P_i - O_i$) valores. (Ver E. 2.49)

$$d = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2}$$

E. 2.49

3 OBJETIVOS

3.1 MOTIVACIÓN

Lo que motiva la investigación de esta tesis se enmarca dentro de las iniciativas para el desarrollo de las Energías Renovables No Convencionales (ERNC) bajo el proyecto INNOVA CORFO “Catastro del Recurso Energético Asociado a Oleaje para el apoyo a la Evaluación de Proyectos de Generación de Energía Undimotriz”, específicamente en la caracterización del clima de olas tanto para aguas profundas como enaguas someras, con el fin de evaluar, con mejor ajuste a la realidad, proyectos de generación de energía undimotriz, lo que permitirá a Chile diversificar y ampliar su matriz energética.

3.2 OBJETIVOS GENERALES

- Mejorar correlaciones entre instrumentos ADCP y Boya TRIAXYS (Transferencias de oleaje), con el fin de que al instalar instrumentos en la costa se pueda crear un ADCP virtual.
- Buscar mejores correlaciones entre resultados obtenidos del modelo WaveWatch III y los resultados obtenidos en terreno, con el fin de ajustar las salidas del modelo mejorando de esta manera su predicción.
- Implementar una herramienta para construir espectros sintéticos por medio de RNA a partir de parámetros de resumen, dado que las metodologías tradicionales imponen la forma de estos, con la RNA se busca representar una forma más cercana a los resultados de los instrumentos.

3.3 OBJETIVOS ESPECÍFICOS

- Verificar la reproducción de las características bimodales del oleaje en los resultados obtenidos de las RNA.
- Comparar distintos tipos de arquitecturas de RNA, con el fin de encontrar la que mejor se ajuste con los espectros medidos (caso espectro sintéticos).
- Comparar resultados de las RNA con otros tipos de metodologías de predicción (modelos ARIMA (Box & Jenkins, 1976)), como también para construcción de espectros sintéticos (JONSWAP (Hasselmann *et al*, 1973)).

4 ALCANCES

Para el entrenamiento y testeo de las redes, los set de datos disponibles para la investigación (Arica, Valparaíso y Lebu) se dividirán en 2 conjuntos: una que contará con el 80% de los datos destinados al entrenamiento de la red, y otra con el 20% correspondiente al set de testeo de la RNA. Si bien Arica se escapa a las delimitaciones del proyecto, se utilizó puesto que se contaba con información suficiente para realiza una aplicación con RNA.

Se realizará una validación cruzada para validar y optimizar los resultados de la RNA.

Mediante el entrenamiento de las redes se ajustarán iterativamente los pesos sinápticos hasta minimizar el error entre el valor deseado y el resultante de la modelación, esto permitirá obtener una correlación más ajustada entre los resultados obtenidos del modelo neuronal y los espectros medidos en aguas someras.

Para el entrenamiento de las redes neuronales se utilizará el software de código libre Multiple-Backpropagation, especializado en redes neuronales artificiales.

La investigación realizada en Lebu consistirá en una mejora en el post-proceso de toma de datos del ADCP por medio de la boya TRIAXYS instalada en aguas profundas. Para esto se analizará mediante una red neuronal que permita buscar una correlación adecuada entre ambos instrumentos. Lo que dará el primer paso para una posterior propagación de oleaje entre ambos instrumentos de medición.

5 HIPÓTESIS

En base a los tres casos que se desea evaluar se plantean las siguientes hipótesis:

- Es posible realizar transferencia de oleaje desde aguas profundas hasta aguas someras, por medio de redes neuronales desde TRIAXYS al ADCP en aguas someras.
- Es posible mejorar la predicción del modelo donde se posee información partir de los parámetros de resumen del WaveWatch III por medio de redes neuronales.
- Es posible implementar una Red Neuronal Artificial (RNA) para desarrollar una herramienta capaz de generar espectros sintéticos a partir de parámetros de resumen del oleaje, con el fin de obtener mejores correlaciones y ajustes más representativos de la realidad (particularmente reproducir bimodalidades del oleaje).

6 METODOLOGÍA

La investigación realizada en esta tesis se efectuó entre el mes de Abril de 2011 hasta Abril 2012 completando un año de dedicación. El lugar en que se desempeñaron las tareas enmarcadas dentro de la investigación fue en el Instituto Nacional de Hidráulica (INH), quienes cedieron un lugar físico para el trabajo y todo el material disponible con el que contaban (en cuanto a literatura e instalaciones).

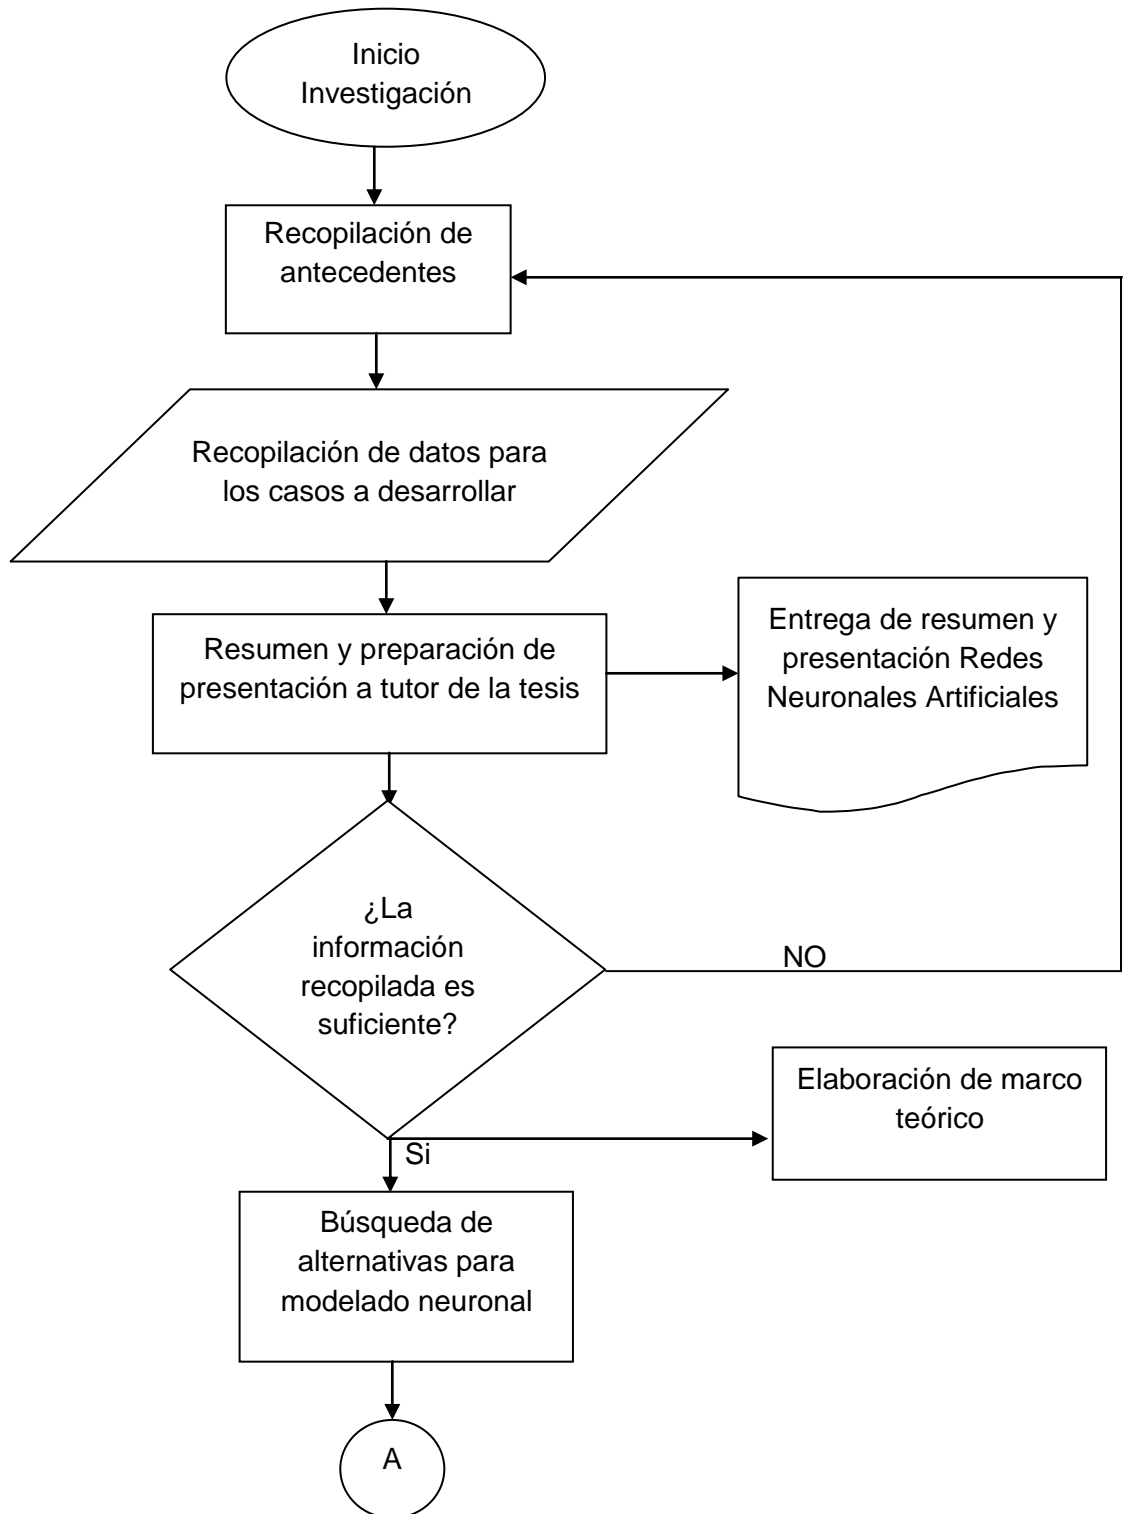
Para la realización de esta investigación se utilizaron software de código abierto u software de licencias gratuitas, como lo son Python (véase sitio web <http://www.python.org/>), Multiple-Backpropagation (N. Lopes & B. Ribeiro, 2009), y la plataforma Ubuntu (Linux).

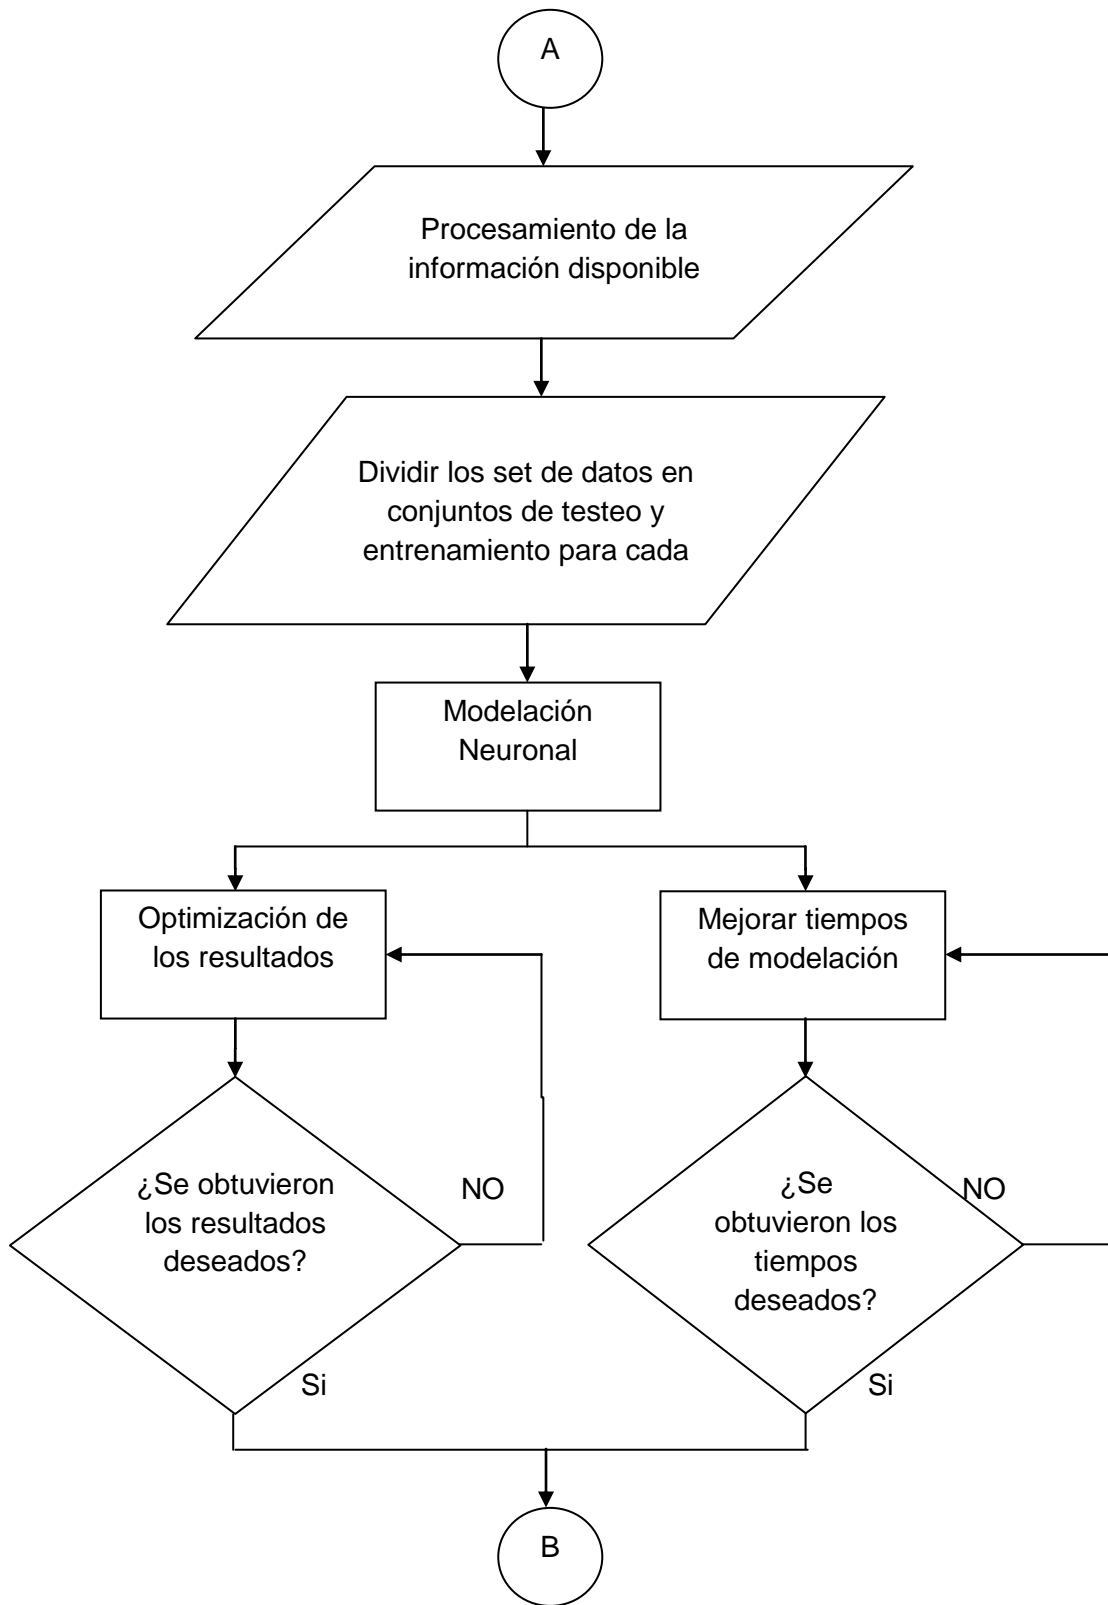
Los datos utilizados para la investigación provienen de dos fuentes: la primera de distribución gratuita correspondiente a WaveWatch III (NOAA) y la segunda amablemente facilitada por el Servicio Hidrográfico y Oceanográfico de la Armada (SHOA) con su set de oleaje de la boya Watchkeeper.

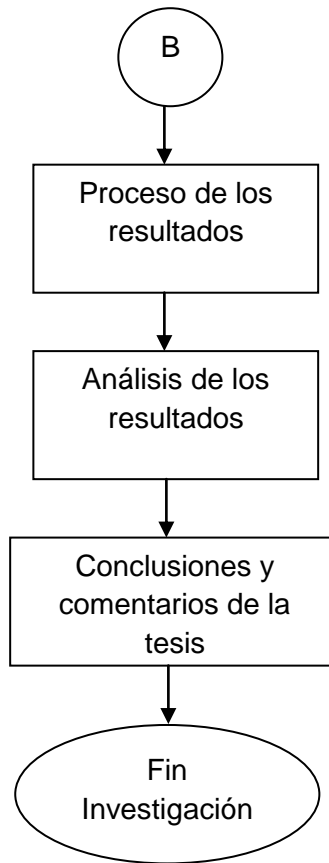
Cabe señalar que si bien el proyecto en el que se enmarca esta investigación presenta delimitaciones geográficas bien definidas (IV Región hasta la X Región), Algunos datos utilizados para esta investigación no se encuentran dentro de ella, esto es debido principalmente a que no se contaba con información suficiente para lograr un buen resultado en las modelaciones neuronales. Por lo que se decidió utilizar un set estadístico de Arica que contaba con una existencia temporal mayor que las demás datas de oleaje. Lo anterior no presenta un perjurio para el proyecto pues se utilizó esta data de manera de comprobar la factibilidad técnica que significa realizar tareas de este tipo para aplicaciones oceánica/marítimas.

En cuanto a los materiales utilizados se pueden señalar específicamente tres; un PC de escritorio (Intel Pentium Dual-Core 3.0 GHz con 2 GB de memoria RAM con un sistema operativo de 32 Bits) facilitado por el proyecto en el que se enmarca esta investigación, y los instrumentos de medición del oleaje (Boya TRIAXYS y dispositivo ADCP).

A continuación se presenta mediante un diagrama de flujo las principales tareas y pasos realizados para la realización de la investigación.







7 RESEÑA DEL PROYECTO

Según informa la Comisión Nacional de Energía (CNE), se estima que en los países con economías emergentes, como es el caso de Chile, el consumo de energía al año 2030 se incrementará en un 57% respecto al año 2004 (Agencia Internacional de Energía). En este contexto, la CNE ha planteado para el país una política energética de largo plazo cuyo objetivo general es: “apoyar un desarrollo sostenible, satisfaciendo la demanda energética de hogares e industrias de manera segura, equitativa, al mínimo costo posible y velando por la preservación de los bienes ambientales y los recursos naturales”. En la actualidad, Chile posee un alto nivel de dependencia energética, donde un gran porcentaje de los recursos energéticos del país son importados. En este escenario, se hace indispensable considerar para el desarrollo sustentable del país, el impulso de nuevas fuentes energéticas que permitan inicialmente suplir la demanda creciente, reducir la dependencia y finalmente fomentar la producción de energías limpias. Es fundamental plantear la búsqueda de fuentes alternativas de energía, en términos de abundancia del recurso y factibilidad técnico-económica de ser implementadas en el corto o mediano plazo. Surgen como posibilidad atractiva, las energías renovables. Éstas suelen clasificarse en convencionales y no convencionales, según sea el grado de desarrollo de las tecnologías para su aprovechamiento y del grado de penetración en los mercados energéticos. Dentro de las convencionales, la más importante es la hidráulica a gran escala. En Chile se define como fuentes de Energías Renovables No Convencionales (ERNC) a las provenientes de: viento, hidráulicas de pequeña escala (hasta 20 MW), biomasa, biogás, geotermia, sol y mar. En esta línea, un nuevo impulso legislativo se plasmó en la Ley 20.257, orientada específicamente al fomento de ERNC. En ella se establece que para el horizonte 2010, un 5% de la oferta proveniente de las empresas comercializadoras debe provenir de fuentes ERNC. Este porcentaje se mantendrá estable hasta el año 2015, a partir del cual se aumentará en forma gradual a razón de 0.5% anual hasta alcanzar un 10% en 2024. Esta exigencia se ha visto traducida en la implementación de proyectos con ERNC de estado maduro, pero al mismo tiempo plantea la necesidad de explorar otras fuentes cuyo nivel de desarrollo actual pudiera dificultar su aplicación comercial inmediata. Dentro de las potenciales nuevas fuentes de energía actualmente en exploración a nivel mundial, se cuentan aquellas provenientes de los océanos.

Estudios de prospección de energía disponible en el mar chileno, provenientes de olas y mareas, sugieren condiciones favorables y factibles para su desarrollo.

Las autoridades, conscientes de esto y con una visión de futuro, están otorgando facilidades para indagar y desarrollar investigación en esta línea. Chile, por su configuración, es uno de los países con mayor potencial en recursos energéticos asociados a oleaje y a corrientes de marea.

Esta condición, energía limpia e inagotable, constituye un gran desafío para la ingeniería nacional. Es necesario generar conocimiento al interior del país, ya que no es posible importar tecnologías foráneas posiblemente desarrolladas para condiciones naturales distintas a las nuestras. En la actualidad a nivel mundial, como se mencionó, estas tecnologías de extracción de energía al mar se encuentran en etapa de desarrollo experimental, por lo que aún no existe la factibilidad técnica y económica para su aplicación a gran escala. Para incorporar en el futuro próximo esta energía a la matriz del país, cuando esté dada la tecnología a nivel comercial, es necesario ahora iniciar y fomentar la investigación en esta línea. En este lineamiento se encuentra el Instituto Nacional de Hidráulica (INH), que por medio de proyectos de investigación, busca aportar y generar conocimiento en cuanto a la disponibilidad y seguridad del recurso energético, identificar sectores favorables, analizar y proponer dispositivos comerciales adecuados al país, etc. Para este efecto se ha conformado una alianza estratégica con quienes se considera actores relevantes para liderar, desarrollar e introducir estas iniciativas energéticas en Chile. La componen las siguientes entidades: el Instituto Nacional de Hidráulica (INH); la Pontificia Universidad Católica de Chile (PUC); la Universidad Técnica Federico Santa María (UTFSM); la Universidad de Valparaíso (UV); la Empresa de Generación de Energía HYDROCHILE; y la Empresa de Ingeniería de Puertos, Costas e Hidráulica PRDW Aldunate Vásquez. Este grupo presentó un proyecto de investigación undimotriz al concurso Innova Chile-Corfo 2009, en la línea de conocimiento del recurso y potencial energético asociado, siendo favorecido, lo que demuestra la confianza de los organismos evaluadores respecto a nuestra propuesta y capacidad.

Es importante resaltar que el océano puede ser utilizado para la generación de energía a través del aprovechamiento de corrientes y mareas. Sin embargo, los procesos físicos asociados al oleaje y las mareas son completamente diferentes y por lo tanto deben ser estudiados en forma independiente.




Figura 7.1: Energía mareomotriz (parque turbinas SeaGen).



Figura 7.2: Energía undimotriz (parque dispositivos Pelamis).

El proyecto de oleaje, denominado “Catastro del Recurso Energético Asociado a Oleaje para el apoyo a la Evaluación de Proyectos de Generación de Energía Undimotriz”, con un monto de 743 millones de pesos, lo lidera el Instituto Nacional de Hidráulica. Este proyecto tiene por objetivo principal el apoyo a la toma de decisión en cuanto a la factibilidad técnico-económica de potenciales proyectos de generación de energía de carácter undimotriz. Para tal efecto, se propone la generación de un catastro del potencial energético del oleaje en la zona centro-sur de Chile, por medio de la medición y modelación de recurso, que permita definir de forma precisa las características del oleaje y la factibilidad técnica de utilizarlo como fuente de energía. Como productos secundarios se generará la capacidad humana para el desarrollo e instalación de sistemas de monitoreo **ad hoc** para la evaluación de este tipo de proyectos, que permita su aplicación en otras zonas geográficas. El INH como parte de este equipo impulsor considera que dar inicio a la investigación para desarrollar e incorporar la energía disponible del mar a la matriz energética de nuestro país, constituye un gran desafío, una enorme responsabilidad y sin duda un gran honor.

Por último cabe mencionar la gran importancia del proyecto en contar con mediciones in-situ con la adquisición de dos boyas TRIAXYS para mediciones de oleaje en aguas profundas y cinco ADCP para mediciones del oleaje en aguas someras, dejando a la investigación como la única en su tipo realizada en Chile con resultados validables mediante datos reales medidos.

8 ANTECEDENTES DE LAS APLICACIONES DE LAS RNA AL ESTUDIO MARÍTIMO-OCEANOGRÁFICO.

En todas las investigaciones desarrolladas los autores concluyeron la enorme capacidad que poseían las RNA para la detección de la no linealidad presente en este tipo de estudios, que quedaba reflejado en los buenos resultados que presentaban, tanto en la predicción como en la correlación, con respecto a las mediciones.

Cabe señalar que las investigaciones realizadas al respecto han sido desarrolladas todas fuera de Chile y que desde el 2003 ya han empezado a ser utilizadas como herramientas de confiables resultados en sus ajustes con la realidad y en su notable capacidad de predicción (siempre y cuando se cuente con información suficiente para lograr un buen entrenamiento de la red). A continuación se nombrarán las aplicaciones de RNA realizadas en el área Oceánica/marítima.

Se encuentra el caso aplicado que a partir de espectro de frecuencia (no direccional) se obtengan los parámetros de resumen (análisis espectral). Se puede señalar la investigación de S. Mandal (Neural Networks for estimation of ocean wave parameters) que aborda esta temática obteniendo parámetros resumen de la ola a partir de un espectro sintético del tipo Pierson-Moskowitz y para otro medido en las costas de Mormugao, India (Figura 8.1).

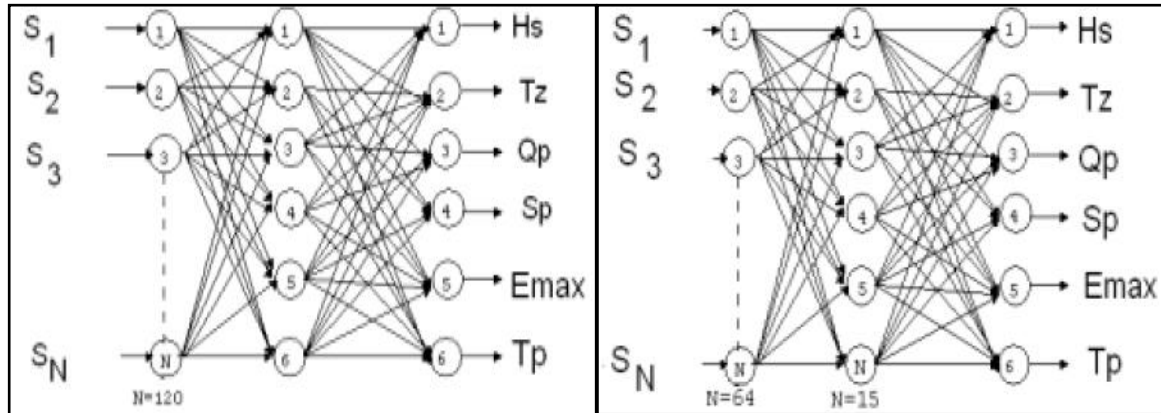


Figura 8.1: Casos investigados por S. Mandal 2004 (RNA izquierda espectro PM, derecha datos de campo)

Dentro de las aplicaciones más destacables de las redes neuronales artificiales se puede mencionar la aplicación para determinar las formas de los espectros de oleaje a partir de parámetros de resumen, obteniendo buenos resultados en la reproducción de las densidades espectrales en el dominio de las frecuencias. Además, comparando estos resultados con métodos empíricos utilizados para la generación de espectros sintéticos como lo son Pierson-Muskowitz y JONSWAP ha demostrado la superioridad de las RNA para la aplicación a este tipo de casos. Podemos encontrar a los siguientes autores que han abordado este tema: Reena Naithani, M.C. Deo (Figura 8.2) y Shailesh Namekar.

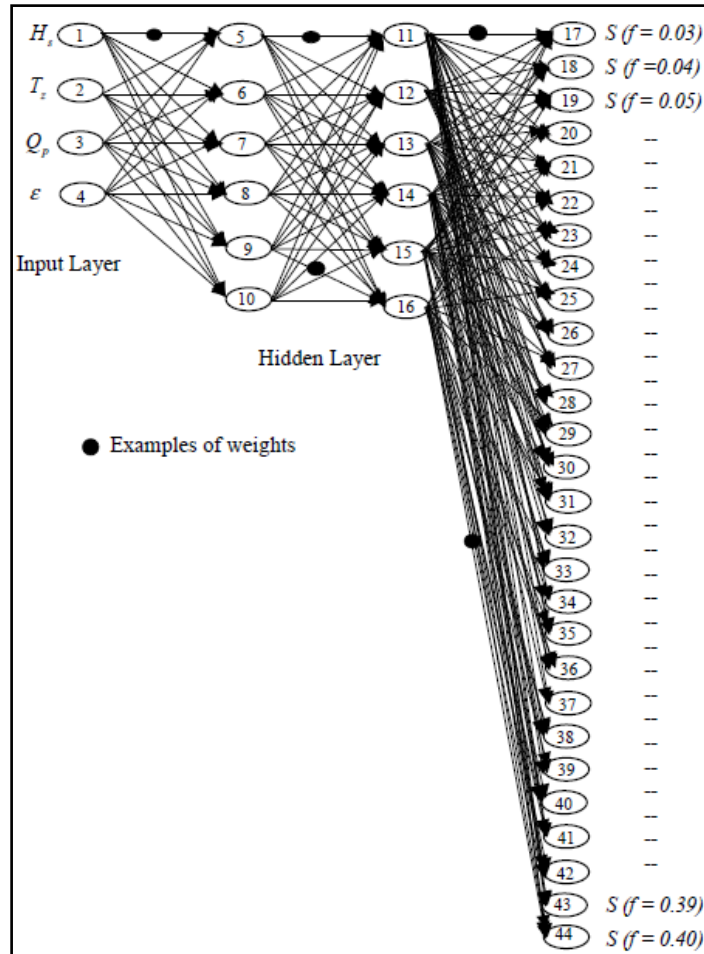


Figura 8.2: Topología de RNA utilizada para la obtención de espectro sintético (Reena Naithani, M.C. Deo 2006)

Existen aplicaciones como la de la investigación (One-Day wave forecasts based on ANN) de Londhe & Vijay Panchang, 2006. Que abordan las predicciones del oleaje mediante la utilización de modelos de generación global como lo son el Wave Model (WAM) y el Simulating Waves Nearshore (SWAN). Pudiendo utilizar la herramienta generada en tiempo real para las predicciones. (Véase Figura 8.3)

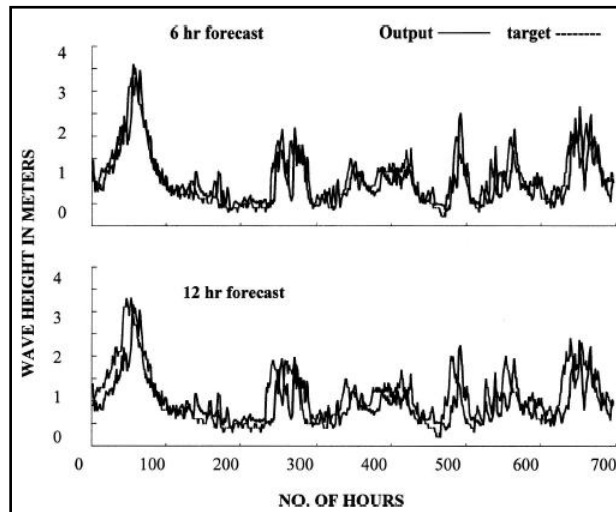


Figura 8.3: Testeo para una serie de altura de ola en tiempo real (Londhe & Vijay Panchang, 2006).

También se han implementados las RNA para la completación de datos faltantes en una serie de tiempo como lo es el caso de la investigación realizada por B. Bhattacharya *et al*, 2003 (Neural Networks in reconstructing missing wave data in sedimentation modelling). Que contaba con dos datos temporales, una de viento que estaba completa y otra de altura de ola que le faltaba el 3% de la información y se esperaba con la RNA reconstruir dicha data (Figura 8.4).

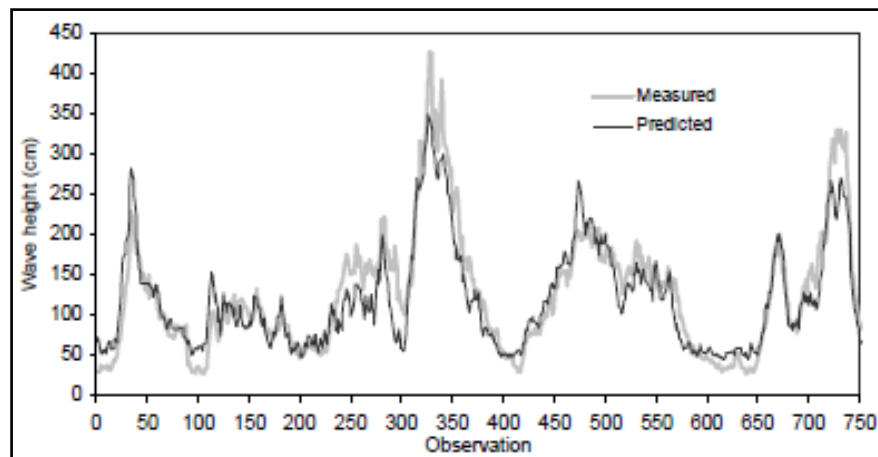


Figura 8.4: Altura significativa estimada por la RNA vs la data medida (Bhattacharya et al, 2003)

Otro tipo de aplicación a la predicción es la investigación realizada por Shailesh Namekar, 2009 (Neural network for tsunami and runup forecast). Donde, mediante a la utilización de redes neuronales se logra crear una herramienta que prediga el comportamiento en la desnivelación y runup de un tsunami, por medio de boyas DART como valor deseado y de dato de entrada modelos de falla plana (Okada, 1985) que define olas de Tsunamis inicial para deslizamiento de subfallas cada 1 a 20 [m] con 1 [m] de intervalo. (Véase Figura 8.5)

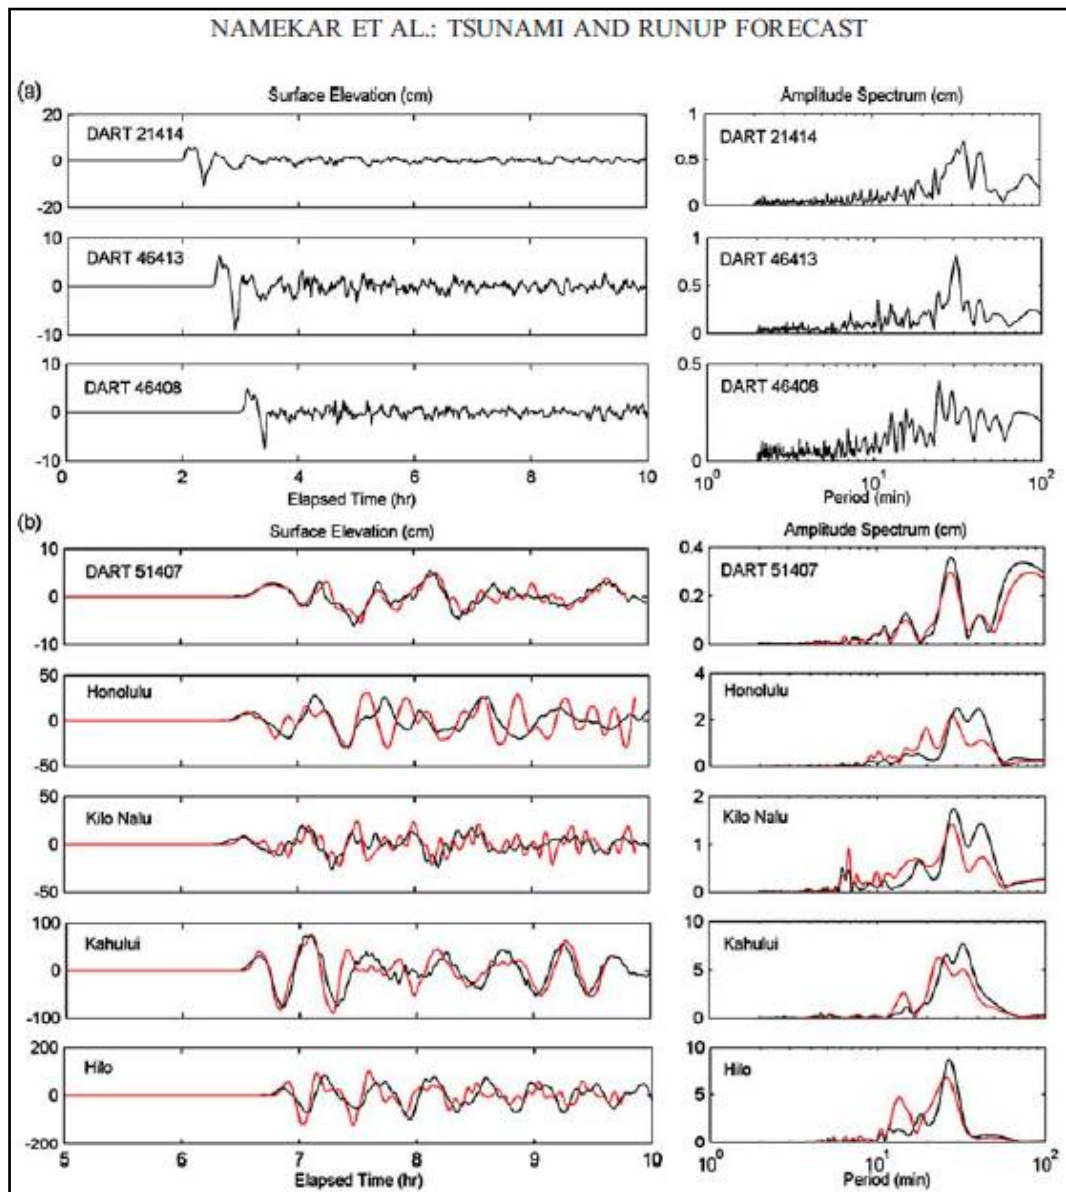


Figura 8.5: a) Input de la data de campo, b) Desnivelaciones alrededor de las Islas de Hawaii. En rojo los resultados obtenidos por la RNA. (Namekar et al, 2009)

9 CASOS ESTUDIADOS

Los resultados serán representados en tres casos cada uno correspondiente a una aplicación de las Redes Neuronales para la ingeniería marítima/oceánica.

9.1 CASO 1: POST-PROCESO ADCP Y TRANSFERENCIA DE OLAJE ENTRE BOYA TRIAXYS Y ADCP, LEBU VIII REGIÓN.

9.1.1 RESEÑA DEL CASO

En el presente caso se estudiará en primer lugar las opciones de cálculo en el proceso de los datos que presenta el instrumento de medición de oleaje ADCP y verificar así mismo la mejor opción para la realización de la propagación. Así mismo se dispone de una boya TRIAXYS ubicada a 150 [m] de profundidad, de esta se obtuvieron parámetros del oleaje útiles para realizar un tipo de transferencia de oleaje desde la boya TRIAXYS hasta el punto de ubicación del ADCP por medio de la RNA (Véase Figura 9.1). Lo que se traduce en mejorar los valores en las correlaciones que se obtienen inicialmente entre la boya TRIAXYS y el ADCP. Para esto se cuenta con una data de algo más de dos meses en escala temporal, la que será detallada más adelante.

Coordenadas boya TRIAXYS : 37° 35' 36.50" S
73° 45' 36.80" W
Coordenadas ADCP : 37° 35' 10.70" S
73° 39' 28,60" W




Figura 9.1: Ubicación de Boya TRYAXIS e Instrumento ADCP, Lebu VIII Región.

9.1.2 PROCESO Y SENSIBILIDAD DE LOS DATOS DISPONIBLES EN ADCP

Para procesar los datos medidos por el ADCP es necesario utilizar la herramienta WavesMon (Teledyne Rd Instrument, 2010). Este software cuenta con métodos de cálculo para la obtención de espectros de densidad de energía de los que a su vez se calcula los parámetros de resumen del oleaje (H_s , T_p , MWD, PWD). Para el cálculo de los espectros la herramienta WavesMon utiliza 4 espectros no direccionales con los que el operario puede decidir cual utilizar.

Los espectros no direccionales se listan a continuación:

- VSpec : Espectro de velocidades
- SSpec : Espectro de aceleraciones
- PSpec : Espectros de presiones
- VPS : (Velocidad, Presiones, Surface (Superficie Libre))

Los gráficos presentados en las siguientes figuras corresponden a los resultados del proceso de los datos del ADCP para distintos tipos de obtención del parámetro altura significativa de la ola. Mediante espectros de presión (Figura 9.2) y espectro de velocidad, presión y superficie libre (Figura 9.3). De ellos se puede observar que en el caso correspondiente al cálculo obtenido del espectro tipo VPS los resultados de la altura significativa fueron ajustados a los datos obtenidos de la boya TRIAXYS en términos de su tendencia y periodicidad.

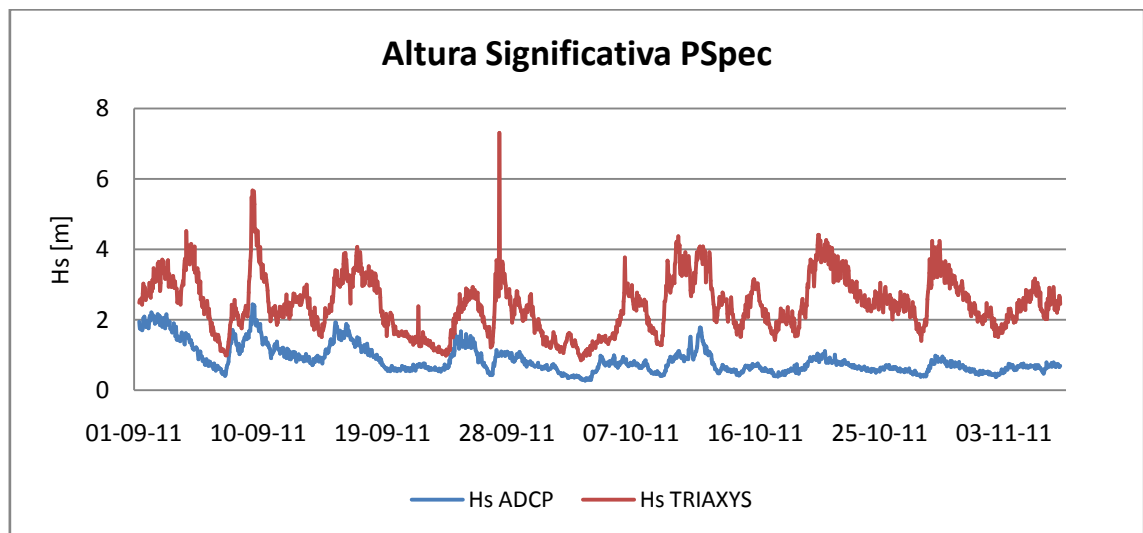


Figura 9.2: Diferencias entre Hs ADCP y Hs TRIAXYS, resultado para PSpec.

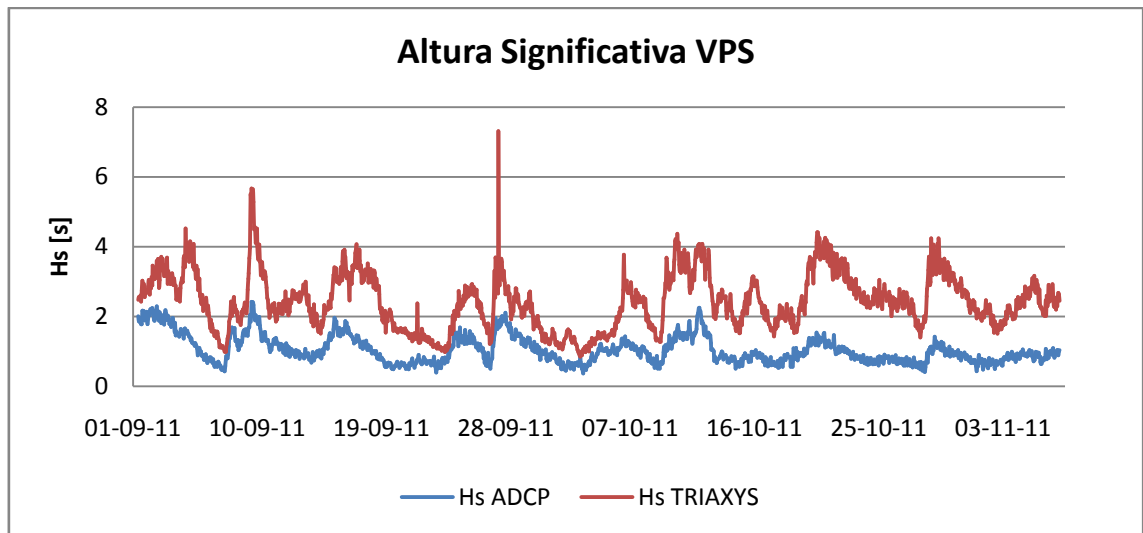


Figura 9.3: Diferencias entre Hs ADCP y Hs TRIAXYS, resultado para VPS.

Los gráficos presentados en las siguientes figuras corresponden a los resultados del proceso de los datos del ADCP para distintos tipos de obtención del parámetro periodo peak de la ola. Mediante espectros de presión (Figura 9.4) y espectro de velocidad, presión y superficie libre (Figura 9.5). De ellos se puede observar que en el caso correspondiente al cálculo obtenido del espectro tipo VPS los resultados del periodo peak son más ajustados a los datos medidos por la boya TRIAXYS.

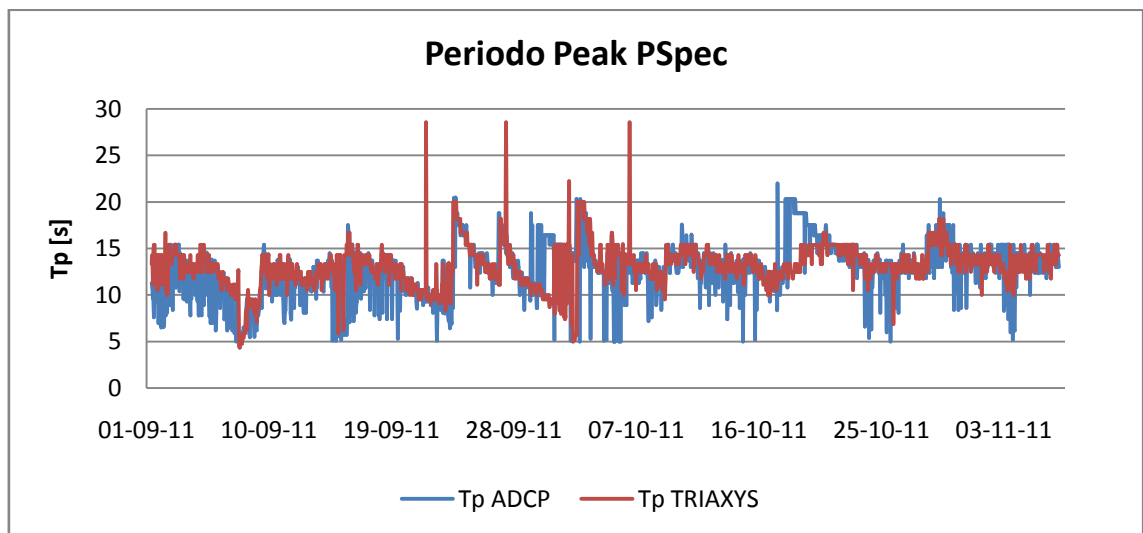


Figura 9.4: Diferencias entre Tp ADCP y Tp TRIAXYS, resultado para PSpec.

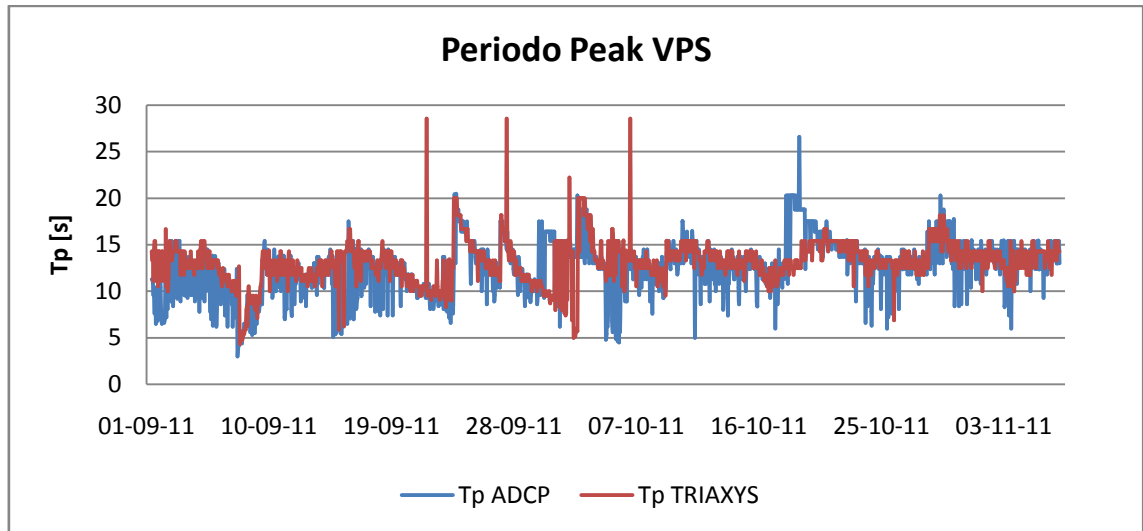


Figura 9.5: Diferencias entre T_p ADCP y T_p TRIAXYS, resultado para VPS.

Los gráficos presentados en las siguientes figuras corresponden a los resultados del proceso de los datos del ADCP para distintos tipos de obtención del parámetro Dirección media de la ola. Mediante espectros de presión (Figura 9.6) y espectro de velocidad (Figura 9.7). De ellos se puede concluir que entre estos dos métodos de cálculo no presentan mayores variaciones siendo ligeramente mejores correlaciones presentadas por el caso donde se utilizó el espectro de presión (PSpec) para la obtención de los resultados.




Figura 9.6: Diferencias entre MWD ADCP y MWD TRIAXYS, resultado para PSpec.

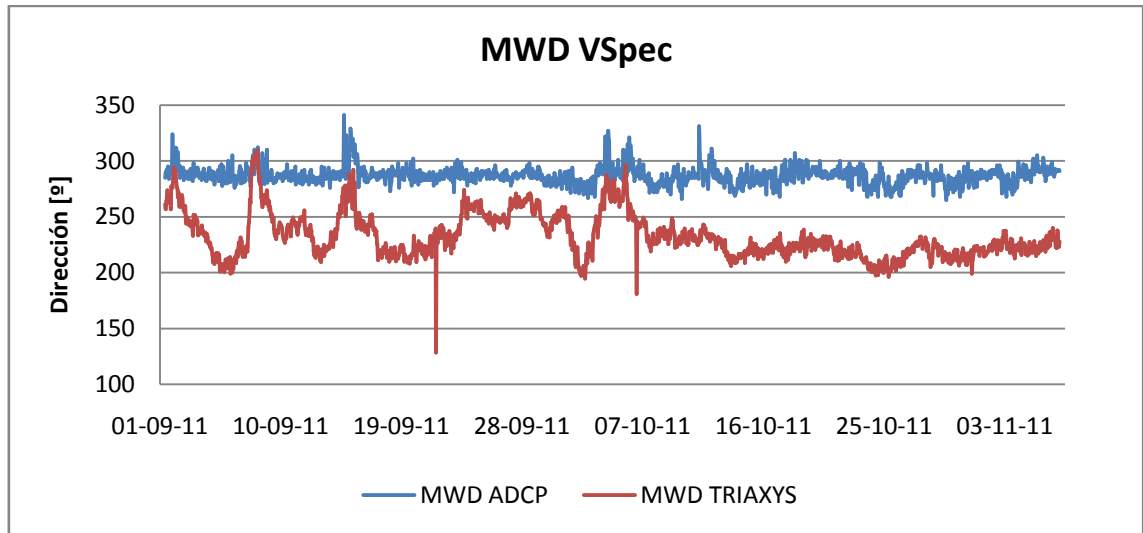


Figura 9.7: Diferencias entre MWD ADCP y MWD TRIAXYS, resultado para VSpec.

La Tabla 9.1 muestra los coeficientes de correlación resaltando los mejores ajustes obtenidos en el proceso de datos del software (TRD WavesMon), fue sensibilizado para distintas FFT Length (parámetro que permite elegir el número exacto de muestra de una serie de tiempo para la trasformada de Fourier) (véase 13.1 Anexo, comparación para 5 espectros) y para las distintas opciones espectrales de cálculo de los parámetros y espectro energéticos de oleaje.

Tabla 9.1: Coeficientes de correlación para los resultados de procesos de datos ADCP

	Coef. De Correlación			
	VSpec	PSpec	VPS	SSpec
Hs	57.19%	57.19%	65.29%	63.33%
Tp	28.03%	38.44%	36.80%	3.03%
MWD	36.78%	39.42%	18.18%	4.73%

De lo anterior se puede concluir que las correlaciones obtenidas para Hs fue las resultante del cálculo de VPS (velocidad, presión y superficie libre) con un 65.29%. Mientras que para el cálculo de MWD y el Tp los mejores resultados en la correlación la presentó PSpec (Espectro de presión) con un 39.42% y 38.44% respectivamente

9.1.3 SET DE DATOS DISPONIBLE PARA MODELAR CON RNA

La data disponible cuenta con 2 meses de parámetros comparables entre el ADCP y la Boya TRIAXYS. Comprendido entre el 01 de Septiembre del 2011 21:00 y el 07 de Noviembre del 2011 16:00

Del cual se dividieron en dos subconjuntos correspondientes al set de entrenamiento que va desde el 01 de Septiembre del 2011 a las 21:00 hasta 23 de Octubre de 2011 21:00 con 52 días y el set de testeo desde el 23 de Octubre del 2011 22:00 hasta el 07 de Noviembre 2011 con un poco más de 14 días. Los datos son medidos cada una hora.

En la Figura 9.8, Figura 9.9 y Figura 9.10 se presentan las series de testeo para altura significativa (Hs), periodo peak (Tp) y dirección media del mar (MWD), respectivamente, para la comparación gráfica entre los datos tomados en terreno tanto el ADCP como de la boya TRIAXYS. De estas Figuras podemos apreciar las diferencias entre los resultados que presentan ambos instrumento, las diferencias son debido principalmente a que la boya TRIAXYS está ubicada en condición de aguas intermedias a una profundidad de 150 [m] en cambio la ADCP se ubica en aguas someras a una profundidad de 15 [m]. Por otro lado comienzan efectos de shoaling lo que produce un decaimiento en la altura significativa de la ola.

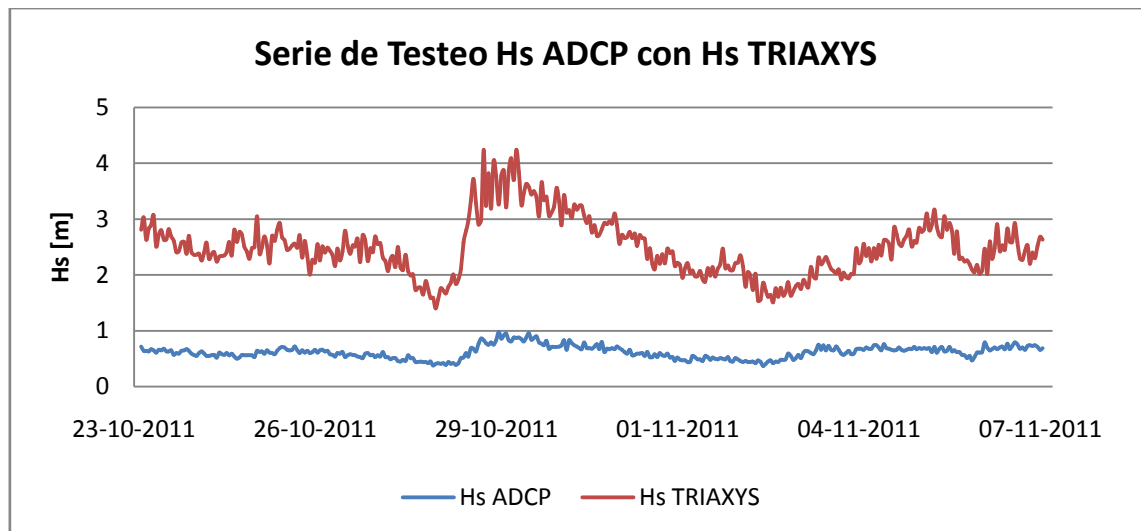


Figura 9.8: Diferencias entre Hs ADCP y Hs TRIAXYS, para el set de testeo de la RNA.




Figura 9.9: Diferencias entre Tp ADCP y Tp TRIAXYS, para el set de testeo de la RNA.

De la Figura 9.10 podemos apreciar la que los frentes de oleaje registrados por los instrumento se encuentran en cuadrantes diferentes, esto se debe principalmente a efectos de difracción presentes en la propagación de la ola entre la boya TRIAXYS y el dispositivo ADCP, quedando reflejado que la que la dirección en aguas profundas se mantiene alrededor de los 220 [°] SW y que en aguas someras (donde se encuentra el ADCP) se acerca a los 280 [°] WNW.




Figura 9.10: Diferencias entre MWD ADCP y MWD TRIAXYS, para el set de testeo de la RNA.

9.1.4 RESULTADOS POST-PROCESO NEURONAL

La Figura 9.11 muestra de manera gráfica la arquitectura de red neuronal utilizada para modelar el caso, esta cuenta con 13 neuronas de entrada correspondiente a los parámetros de resumen obtenidos de la boya TRIAXYS, luego dos capas ocultas con 10 neuronas cada una y por último las neuronas de salidas.




Figura 9.11: Arquitectura utilizada para el entrenamiento de la RNA.

En la Figura 9.12 se puede observar como la RNA pudo ajustar de una buena manera la variabilidad de la altura del oleaje, representando sus peak y siguiendo con una buena calidad la tendencia de la serie. Además la figura cuenta con una gráfica del residuo (error) entre el dato medido por ADCP y el resultado de la red, donde se puede obtener que el error máximo alcanzado es de 0.27 [m] y un error promedio de 0.065 [m].




Figura 9.12: Diferencias entre el resultado Hs ADCP y Hs RNA

En la Figura 9.13 si bien se puede apreciar que las series no están ajustadas respecto a los resultados presentados por la altura significativa, se observa una mejora en la tendencia de las muestras y un acercamiento entre ambas series. Además analizando los residuos se puede señalar que el error máximo entre las series es de 7.9 [s] mientras que el error medio de tan solo de 1.39 [s].




Figura 9.13: Diferencias entre el resultado Tp ADCP y Tp RNA

En la Figura 9.14 presenta los resultados obtenidos por la RNA respecto a las direcciones peak medidas por el ADCP, y del análisis de los residuos se puede señalar que el error máximo es de 24.7 [°] mientras que el error medio es de 5.9 [°].




Figura 9.14: Diferencias entre el resultado PWD ADCP y PWD RNA

La Figura 9.15 presenta los resultados obtenidos por la RNA respecto a las direcciones medias medidas por el ADCP, y del análisis de los residuos se puede señalar que el error máximo es de 21.5 [°] mientras que el error medio es de 5.6 [°].




Figura 9.15: Diferencias entre el resultado MWD ADCP y MWD RNA

La Tabla 9.2 presenta los resultados obtenidos del entrenamiento de la red neuronal que mostró los mejores drs respecto a los datos medidos, además muestra los errores medios cuadráticos (RMS) obtenidos para los parámetros testeados.

Tabla 9.2: Resultados del testeo de la RNA

Resultados		
Parámetro	Ajuste	RMS
Hs [m]	0.878	0.08
Tp [s]	0.533	1.98
MWD [°]	0.539	7.29
PWD [°]	0.574	7.60

9.1.5 ENTRENAMIENTO DE RNA INCORPORANDO RETARDO DE LA OLA ENTRE INSTRUMENTOS (T-1)




Figura 9.16: Arquitectura de RNA incorporando retraso de la ola entre instrumentos

Los resultados anteriores no consideran el retraso que tiene la ola entre un instrumento al otro, lo que no es algo fundamental de considerar para el caso de la modelación con redes neuronales, pero a modo de ejercicio se procedió al entrenamiento de una nueva topología de red pero que en esta se incluyera el dato de la ola anterior (una hora antes) y también el de la ola a la misma hora. Quedando finalmente una red con 26 neuronas de entradas y 4 neuronas de salidas con dos capas de 15 neuronas ocultas cada una (véase Figura 9.16).

Al colocar la nomenclatura (T-1) se hace referencia a que los resultados incluyen el tiempo que demora la ola en llegar desde el punto en que encuentra la boya al punto donde se encuentra el dispositivo ADCP. Como los datos se encuentran espaciados cada 1 hora, se procedió a entrenar en los nodos de entrada de la red, el tiempo simultáneo y el

tiempo anterior (1 horas antes) de los instrumentos de medición, para asegurar una mejor captura de la información contenida en los estados de mar.

La Figura 9.17 muestra las bandas de confianza de 95% respecto a la regresión cuadrática de los datos observados con la desviación estándar para los resultados obtenidos de las redes neuronales al parámetro de la Altura significativa de la ola.




Figura 9.17: Bandas de confianza 95% para testeo de RNA Hs.

En la Figura 9.18 se presenta el residuo, donde puede observarse que error máximo obtenido entre la salida de la red con respecto al valor obtenido del ADCP, para la altura significativa, es de 0.24 [m], mientras el promedio del error es de 0.06 [m].




Figura 9.18: Gráfico del error (residual) para la RNA Hs.

El histograma presentado en la Figura 9.19, muestra el error acumulado en porcentaje entre el dato medido in-situ (ADCP) y el dato predicho por la RNA. De esta gráfica se puede señalar que la mayor acumulación del error se presenta para alturas de oleaje menores a 0.1 [m] y dejando sólo un 20% de error en la predicción para valores que no sobrepasan los 0.24 [m].




Figura 9.19: Histograma del error Hs (ADCP-RNA)

La Figura 9.20 muestra las bandas de confianza de 95% respecto a la regresión cuadrática de los datos observados con la desviación estándar para los resultados obtenidos de las redes neuronales el parámetro del periodo peak de la ola.




Figura 9.20: Bandas de confianza 95% para testeo de RNA Tp.

En la Figura 9.21 se presenta el gráfico del error del se puede obtener que el error máximo obtenido entre la salida de la red con respecto al valor obtenido del ADCP, para el periodo peak, es de 7.9 [s], mientras el promedio del error es de 1.4 [s].




Figura 9.21: Gráfico del error (residual) para la RNA Tp.

El histograma presentado en la Figura 9.22, muestra el error acumulado en porcentaje entre el dato medido in-situ (ADCP) y el dato predicho por la RNA. De esta gráfica se puede señalar que la mayor acumulación del error se presenta para periodos peak de oleaje menores a 3 [s] con una acumulación del 87%, y con un error máximo de 7.9 [s].




Figura 9.22: Histograma del error Tp (ADCP-RNA)

La Figura 9.23 muestra las bandas de confianza de 95% respecto a la regresión cuadrática de los datos observados con la desviación estándar para los resultados obtenidos de las redes neuronales el parámetro de la dirección peak de la ola.




Figura 9.23: Bandas de confianza 95% para testeo de RNA PWD.

En la Figura 9.24 se presenta el gráfico del error del se puede obtener que el error máximo obtenido entre la salida de la red con respecto al valor obtenido del ADCP, para la dirección peak de la ola, es de 25.5 [°], mientras el promedio del error es de 5.8 [°].




Figura 9.24: Gráfico del error (residual) para la RNA PWD.

El histograma presentado en la Figura 9.25, muestra el error acumulado en porcentaje entre el dato medido in-situ (ADCP) y el dato predicho por la RNA. De esta gráfica se puede señalar que la mayor acumulación del error se presenta para dirección peak de oleaje menores a 16 [°] con una acumulación del 95%, y con un error máximo de 25.5 [°].




Figura 9.25: Histograma del error PWD (ADCP-RNA)

La Figura 9.26 muestra las bandas de confianza de 95% respecto a la regresión cuadrática de los datos observados con la desviación estándar para los resultados obtenidos de las redes neuronales el parámetro de la dirección media de la ola.




Figura 9.26: Bandas de confianza 95% para testeo de RNA MWD.

En la Figura 9.27 se presenta el gráfico del error del se puede obtener que el error máximo obtenido entre la salida de la red con respecto al valor obtenido del ADCP, para la dirección media de la ola, es de 20.7 [°], mientras el promedio del error es de 5.8 [°].




Figura 9.27: Gráfico del error (residual) para la RNA MWD.

El histograma presentado en la Figura 9.28, muestra el error acumulado en porcentaje entre el dato medido in-situ (ADCP) y el dato predicho por la RNA. De esta gráfica se puede señalar que la mayor acumulación del error se presenta para dirección media de oleaje menores a 15 [°] con una acumulación del 92%, y con un error máximo de 20.7 [°].




Figura 9.28: Histograma del error MWD (ADCP-RNA)

En la Tabla 9.3 y se aprecian los resultados para este experimento. De los valores se puede apreciar que las mejores correlaciones fueron logradas para la altura significativa con una correlación de 80.38% y una desviación estándar de 0.12, con un RMS 0.08 [m], mientras que para el periodo peak el RMS fue de 1.98 [s] y para las direcciones tanto peak como media presentados un error de RMS de 7.52 [°].

Tabla 9.3: Resultados de la RNA incorporando retraso de ola entre instrumentos

Resultados (T-1)			
Parámetro	Ajuste	RMS	Desv. Estánd.
Hs	0.892	0.08	0.13
Tp	0.533	1.98	1.02
MWD	0.561	7.52	3.01
PWD	0.589	7.53	3.17

En la Tabla 9.4 se presenta la comparación entre los resultados de los ensayos realizados incluyendo el retardo que sufre la ola hasta llegar a la costa y sin considerar este retraso (tiempo que se demora la ola en recorrer desde la Boya TRIAXYS hasta el ADCP). De la tabla se puede apreciar el incremento de todos los parámetros en la correlación de su resultado. Además la tabla presenta los errores medios cuadráticos alcanzados en el entrenamiento y en la comparación de los dos experimentos realizados (considerando y sin considerar el retraso de la ola). Presentando una disminución del error, entre el dato medido y el resultado RNA, en todos los parámetros excepto la dirección media para el caso de (T-1).

Tabla 9.4: Comparación entre resultados con retardo de la ola y resultados sin retardo

Parámetro	Resultados (T-1)		Resultados (T)		Mejora	
	Ajuste	RMS	Ajuste	RMS	Ajuste	RMS
Hs	89.23%	0.076	87.75%	0.084	1.48%	-0.008
Tp	53.30%	1.981	53.29%	1.982	0.01%	-0.002
MWD	56.10%	7.516	53.91%	7.288	2.19%	0.228
PWD	58.87%	7.525	57.37%	7.601	1.49%	-0.076

9.1.6 RESULTADO MÉTODO PREDICTIVO ARIMA

Cabe señalar que todas las modelaciones realizadas con ARIMA proyectaron 150 pasos al futuro en la predicción, lo que se traduce a 6 días de testeo. Esta proyección se debió principalmente a la pérdida de precisión en el modelo para reproducir la serie con una extensión mayor de testeo.

Del resultado de la predicción por el método ARIMA para Hs se obtiene un índice de ajuste de 42.26%, con un error máximo de 0.45 [m] y un error medio de 0.09 [m]. (Véase Figura 9.29)

Parámetros modelo ARIMA utilizados:

- Periodos : 31
- Autorregresivo no estacionario : 3
- Autorregresivo estacionario : 1
- Diferencias no estacionarias : 0
- Diferencias estacionarias : 1




Figura 9.29: Predicción método ARIMA para Hs (ADCP-Lebu)

Del resultado de la predicción por el método ARIMA para T_p se obtiene un índice de ajuste de 37.97%, con un error máximo de 10.04 [s] y un error medio de 2.3 [s]. (Véase Figura 9.30)

Parámetros modelo ARIMA utilizados:

- Periodos : 20
- Autorregresivo no estacionario : 2
- Autorregresivo estacionario : 2
- Diferencias no estacionarias : 0
- Diferencias estacionarias : 1




Figura 9.30: Predicción método ARIMA para T_p (ADCP-Lebu)

Del resultado de la predicción por el método ARIMA para PDW se obtiene un índice de ajuste de 46.15%, con un error máximo de 32.02 [°] y un error medio de 9.85 [°]. (Véase Figura 9.31)

Parámetros modelo ARIMA utilizados:

- Periodos : 40
- Autorregresivo no estacionario : 2
- Autorregresivo estacionario : 2
- Diferencias no estacionarias : 0
- Diferencias estacionarias : 1




Figura 9.31: Predicción método ARIMA para PWD (ADCP-Lebu)

Del resultado de la predicción por el método ARIMA para MDW se obtiene un índice de ajuste de 43.77%, con un error máximo de 24.4 [°] y un error medio de 7.7 [°]. (Véase Figura 9.32)

Parámetros modelo ARIMA utilizados:

- Periodos :22
- Autorregresivo no estacionario : 4
- Autorregresivo estacionario : 0
- Diferencias no estacionarias : 0
- Diferencias estacionarias : 1




Figura 9.32: Predicción método ARIMA para MWD (ADCP-Lebu)

Tabla 9.5: Comparación entre resultados RMA y ARIMA

Parámetro	Resultados RNA (T-1)		Resultados ARIMA		Mejora	
	Ajuste	RMS	Ajuste	RMS	Ajuste	RMS
Hs [m]	89.23%	0.076	42.26%	0.13	46.97%	0.054
Tp [s]	53.30%	1.981	37.97%	2.88	15.33%	0.899
MWD [°]	56.10%	7.516	43.77%	9.73	12.32%	2.214
PWD [°]	58.87%	7.525	46.15%	12.21	12.72%	4.685

9.1.7 COMENTARIOS Y CONCLUSIONES

Analizando los errores obtenidos entre las RNA y el valor medido en el entrenamiento y en la comparación de los dos experimentos realizados (considerando y sin considerar el retraso de la ola). Presentaron una disminución del error, entre el dato medido y el resultado RNA, en todos los parámetros excepto la dirección media para el caso de (T-1) (véase Tabla 9.4). Para la altura significativa se obtuvo un RMS de 0.076m, para el periodo peak 1.98s y tanto para las direcciones peak y media se obtuvieron RMS de 7.5°, lo que presenta un error aceptable para el estudio de clima medio del oleaje en base a parámetros de resumen.

En términos de ajustes la altura significativa, que presentó la mejor correlación entre resultados RNA con respecto a los datos medidos, presentó un incremento en 3.93 puntos porcentuales, mientras que para el periodo peak obtuvo una mejora de 0.08% y la dirección media resultó con una mejora del 13.30%. Además se obtuvieron resultados para dirección peak del oleaje, parámetro que no fue introducido en las neuronas de entrada (Boya TRIAXYS) pero si en las neuronas de Salida (datos ADCP), del cual se obtuvieron correlaciones de 58.61%.

Principalmente la mejora de los resultados de las predicciones de las RNA respecto a los datos medidos, no fue sustancial debido a la limitada extensión temporal de los datos utilizados para el entrenamiento de las redes neuronales, lo que no permitió generalizar de una forma efectiva las variabilidades y el reconocimiento de los patrones no lineales presentes en la estadística disponible.

Por último comparando los resultados obtenidos con la RNA con el método predictivo ARIMA (véase Tabla 9.5), las redes superan ampliamente tanto en el ajuste de sus resultados como en la disminución del RMS. Mientras que si se analizan los resultados presentados por los RMS (error medio cuadrático) son más bien discretas donde las mayores mejoras fueron presentadas para los parámetros de la dirección peak y dirección media, con una disminución del RMS de 4.69° y 2.21° respectivamente.

9.2 CASO 2: HERRAMIENTA RNA QUE BUSCA MEJORAR LOS PARÁMETROS OBTENIDOS DE NOAA (WAVEWATCH III) A VALORES MEDIDOS IN-SITU.

9.2.1 RESEÑA DEL CASO

En el presente caso se aplicarán las Rede Neuronales Artificiales a la mejora en la correlación de los datos obtenidos del modelo WaveWatch III desarrollado por el NOAA (véase sitio FTP <ftp://polar.ncep.noaa.gov/pub/history/waves>) y teniendo el valor deseado a los datos entregado por boya Watchkeeper, esto con el fin de poseer una primera aproximación a la factibilidad de realizar de una RNA que permita a través de datos extraídos de NOAA, que contiene una larga data de información en parámetros de resumen (Altura significativa, periodos peak, dirección peak, vientos en U y V), ajustar con los datos entregado por las Boyas TRIAXYS instalas por el proyecto en la que se enmarca esta tesis.

La Figura 9.33 muestra las zonas de aplicación del modelo de generación de oleaje NOAA, donde se extrajeron los parámetros de la ola, del módulo global que contiene las latitudes en las que se encuentra Chile.

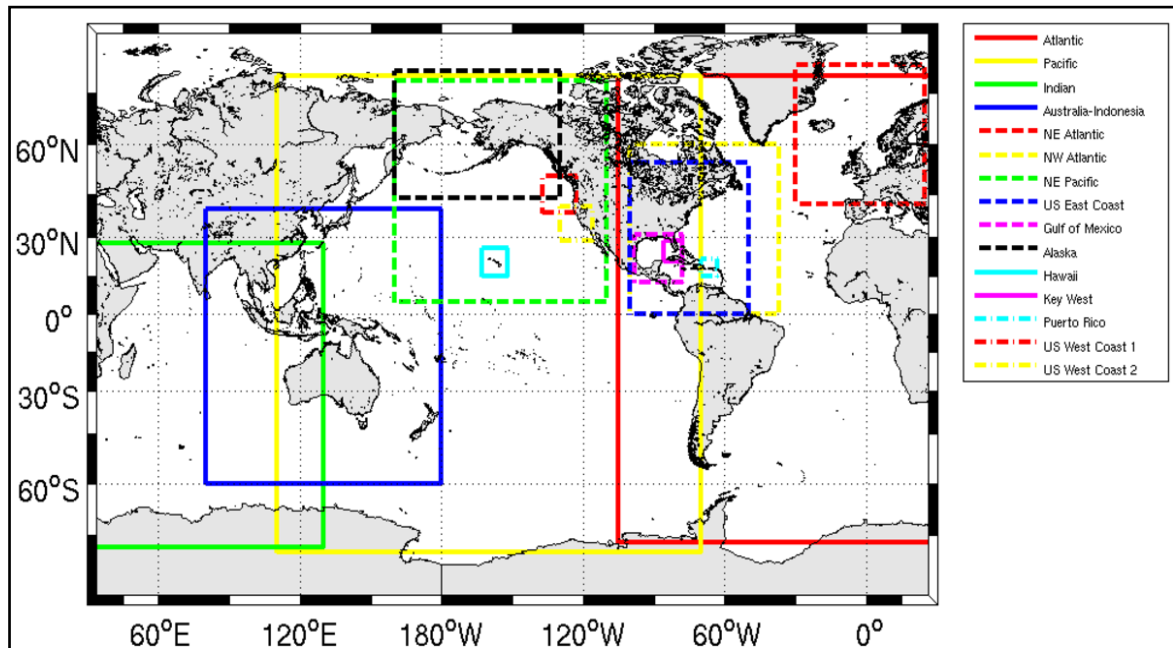


Figura 9.33: Zonas de aplicación de los modelos del WaveWatch III (NOAA)

9.2.2 PROCEDIMIENTO

Una vez descargada la información del sitio FTP de la NOAA, esta se procesará para obtener los parámetros de oleaje del punto al que se someterá el estudio. Con esta información disponible se entrenará una red neuronal con el fin de obtener un mejor ajuste de la realidad en base a las mediciones de campo. Con esta herramienta se logra a partir de la información proporcionada por WaveWatch III obtener parámetros resumen en una alta fidelidad con respecto a la realidad.

Desde el sitio FTP de NOAA es posible obtener la altura significativa [Hs], periodos peak [Tp], dirección media [MWD], dirección peak [PWD], y componente de velocidad u y v del viento, cada 3 horas.

Se cuenta con un set de datos de 1 año con 10 meses, el cual se dividirá en dos tramos: El primero de extensión temporal de 1 año y medio correspondiente al set de entrenamiento, y el restante será para el testeo de la RNA. El set de datos corresponde al nodo frente a las costas de Arica.

9.2.3 RESULTADOS

En la Tabla 9.6 se presentarán los resultados obtenidos para las distintas alternativas testeadas con las RNA. En esta tabla se exponen los casos como “no optimizados” en referencia a que el número de iteraciones fue común para todas las alternativas. Quedando finalmente con una detención en la iteración número 5000.

Tabla 9.6: Resumen de resultados modelación RNA casos no optimizados.

Caso		Alternativas de Arquitectura de RNA (no optimizado)				
		5-10-1	5-15-1	5-10-10-1	5-10-15-1	5-15-20-1
Hs	RMS Train (m)	0.201	0.204	0.206	0.199	0.202
	RMS testeo (m)	0.261	0.264	0.257	0.262	0.256
	Ajuste (%)	92.21	92.64	91.16	92.76	91.93
	Desv. Estándar	0.43	0.42	0.41	0.42	0.42
	Iteraciones	5000	5000	5000	5000	5000
Tp	RMS Train (s)	1.133	1.116	1.139	1.116	1.126
	RMS testeo (s)	1.088	1.131	1.081	1.077	1.076
	Ajuste (%)	83.43	84.07	84.51	83.50	83.36
	Desv. Estándar	1.28	1.25	1.27	1.25	1.29
	Iteraciones	5000	5000	5000	5000	5000
MWD	RMS Train (°)	5.073	5.157	5.067	5.702	5.197
	RMSE testeo (°)	3.723	3.698	3.670	3.813	3.743
	Ajuste (%)	89.16	89.21	89.07	86.97	89.51
	Desv. Estándar	5.93	5.74	5.83	4.64	5.61
	Iteraciones	5000	5000	5000	5000	5000
PWD	RMS Train (°)	6.127	6.002	6.292	6.277	6.048
	RMS testeo (°)	4.081	4.086	3.979	3.949	4.045
	Ajuste (%)	92.33	92.30	92.54	92.59	92.34
	Desv. Estándar	7.28	7.28	7.10	7.05	7.16
	Iteraciones	5000	5000	5000	5000	5000
TODOS INCLUIDOS	RMS Train	3.155	3.403	3.086	3.076	3.012
	RMS testeo	2.285	2.322	2.332	2.405	2.291
	Ajuste (%)	84.55	86.74	88.16	86.43	86.40
	Iteraciones	5000	5000	5000	5000	5000

Los valores optimizados presentados en las siguientes figuras (Figura 9.35, Figura 9.39, Figura 9.43, y Figura 9.47), corresponden a entrenamientos que fueron detenidos procurando alcanzar el mínimo posible de los errores en el ajuste de los datos medidos en terreno con los modelados en la red. Mientras que en la En la Tabla 9.6 se presentarán los resultados obtenidos para las distintas alternativas testeadas con las RNA. En esta tabla se exponen los casos como “no optimizados” en referencia a que el número de iteraciones fue común para todas las alternativas. Quedando finalmente con una detención en la iteración número 5000.

Tabla 9.6 se presenta los resultados de los entrenamientos detenidos a las 5000 iteraciones. Esto se hizo con el fin de determinar qué tan preponderante era para este caso, el alcanzar un mínimo deteniendo el proceso o dejar que convergiera en un valor bajo un “stop” predeterminado de las iteraciones para el entrenamiento.




Figura 9.34: Arquitectura de RNA para entrenamiento de Hs

La Figura 9.34 presenta, como ejemplo, el esquema de la arquitectura neuronal óptima para el entrenamiento de la altura significativa para este caso. En donde se utilizaron 5 neuronas de entrada obtenidas de los resultados de NOAA, con dos capas ocultas, la primera de 15 neuronas y la segunda de 20 neuronas, y una neurona de salida con Hs como valor deseado, con una función de activación del tipo logística. Se llegó a esta configuración (arquitectura neuronal) después de testear varias otras arquitecturas con el fin alcanzar el mínimo error en el ajuste entre la predicción RNA y el valor medido.

En los resultados obtenidos por las redes neuronales se puede apreciar que para la altura significativa presenta un buen ajuste con el dato obtenido del set de Watchkeeper, representando una correcta relación en las tendencias de la serie como las variabilidades propias de la altura significativa en el oleaje. En lo que se pierde fidelidad en la correlación es en los peak en sus límites extremos de la serie (Figura 9.35)




Figura 9.35: Comparación set de oleaje Watchkeeper (SHOA) y resultado de RNA para Hs

En la Figura 9.36 se presenta el gráfico del error del se puede obtener que el error máximo obtenido entre la salida de la red con respecto al valor medido obtenido de la boyea Watchkeeper, para la altura significativa, es de 0.96 [m], mientras el promedio del error es de 0.21 [m].




Figura 9.36: Error o residuo entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para Hs.

El histograma presentado en la Figura 9.37, muestra el error acumulado en porcentaje entre el dato medido in-situ (Watchkeeper) y el dato predicho por la RNA. De esta gráfica se puede señalar que la mayor acumulación del error se presenta para altura significativa de oleaje menores a 0.38 [m] con una acumulación del 88%, y con un error máximo de 0.91 [m].




Figura 9.37: Histograma del error Hs (Watchkeeper-RNA)

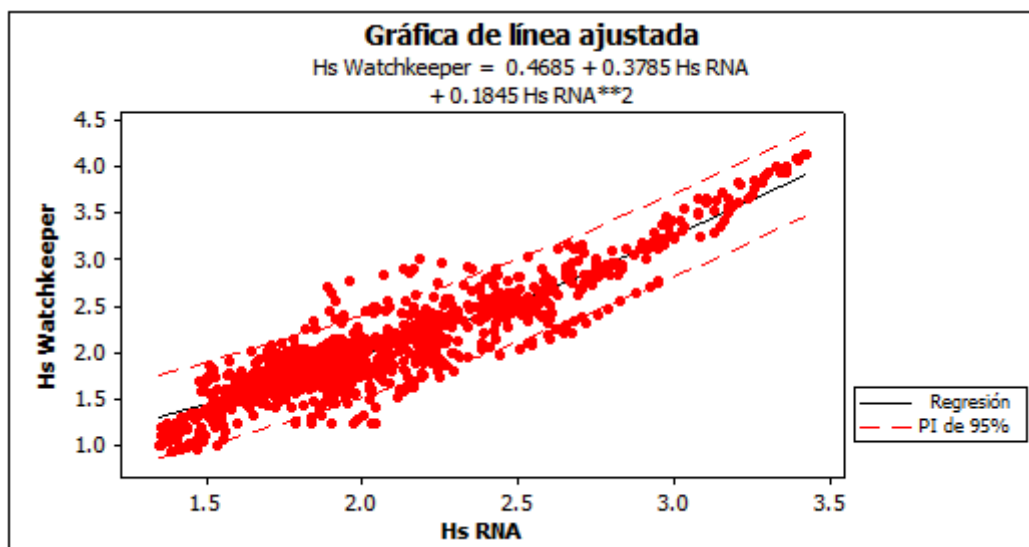


Figura 9.38: Bandas de confianza 95% para testeo de RNA Hs (Caso 2).

En cuando a los periodos si bien estos presentaron un buen ajuste en la serie, se repite con mayor notoriedad la baja precisión en la reproducción de periodos sobre los 16 [s] y menores a los 12 [s] (Figura 9.39). Además produce un error máximo entre el medido y el resultante de la red de 5.5 [s] con un error promedio de 0.7 [s] (véase Figura 9.40)




Figura 9.39: Comparación entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para Tp




Figura 9.40: Error o residuo entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para Tp.

El histograma presentado en la Figura 9.41, muestra el error acumulado en porcentaje entre el dato medido in-situ (Watchkeeper) y el dato predicho por la RNA. De esta gráfica se puede señalar que la mayor acumulación del error se presenta para periodo peak de oleaje menores a 2 [s] con una acumulación del 95%, y con un error máximo de 5.5 [s].

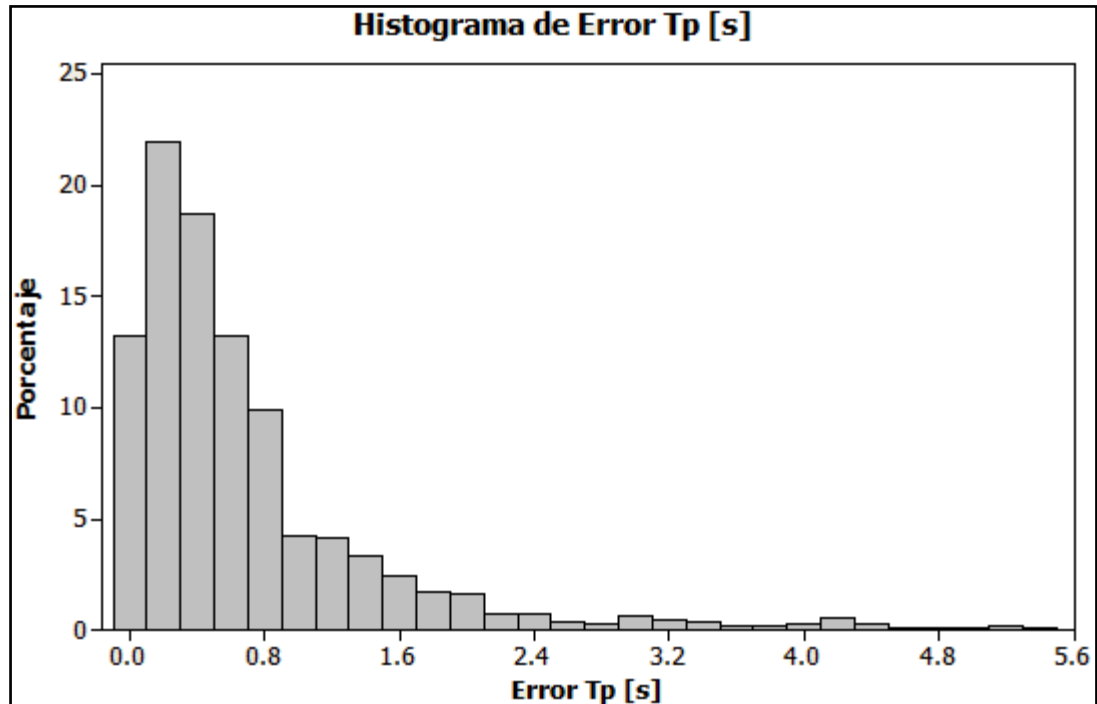


Figura 9.41: Histograma del error Tp (Watchkeeper-RNA)




Figura 9.42: Bandas de confianza 95% para testeo de RNA Tp (Caso 2).

De la Figura 9.43 y Figura 9.47 se puede apreciar el buen ajuste presente en las salidas de la red con respecto a los datos tomados de la boya Watchkeeper (SHOA). Los gráficos presentan los resultados para las arquitecturas óptimas para la reducción en el error de la correlación.




Figura 9.43: Comparación entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para MWD




Figura 9.44: Error o residuo entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para MWD.

El histograma presentado en la Figura 9.45, muestra el error acumulado en porcentaje entre el dato medido in-situ (Watchkeeper) y el dato predicho por la RNA. De esta gráfica se puede señalar que la mayor acumulación del error se presenta para dirección media de oleaje menores a 7 [°] con una acumulación del 91%, y con un error máximo de 12.7 [°].




Figura 9.45: Histograma del error MWD (Watchkeeper-RNA)

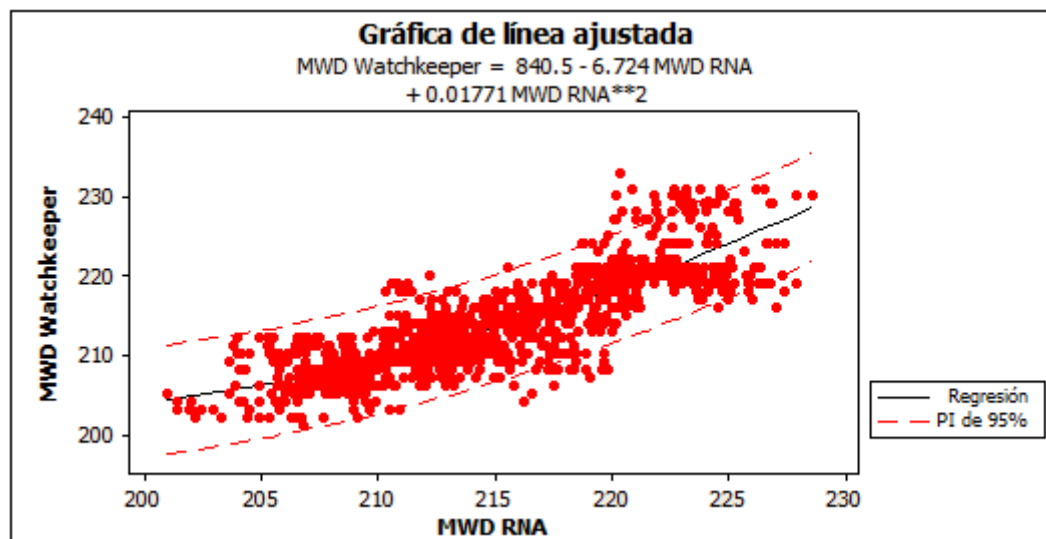


Figura 9.46: Bandas de confianza 95% para testeo de RNA MWD (Caso 2).

En la Figura 9.44 se presenta los resultados de la RNA con respecto a los valores medido para la dirección media del oleaje, además del análisis de los residuos se puede obtener un error máximo de 12.7 [°], mientras el promedio del error es de 2.9 [°].




Figura 9.47: Comparación entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para PWD




Figura 9.48: Error o residuo entre set de oleaje Watchkeeper (SHOA) y resultado de RNA para PWD

En la Figura 9.48 se presenta los resultados de la RNA con respecto a los valores medido para la dirección peak del oleaje, además del análisis de los residuos se puede obtener un error máximo de 23.2 [°], mientras el promedio del error es de 2.5 [°].

El histograma presentado en la Figura 9.49, muestra el error acumulado en porcentaje entre el dato medido in-situ (Watchkeeper) y el dato predicho por la RNA. De esta gráfica se puede señalar que la mayor acumulación del error se presenta para dirección peak de oleaje menores a 9 [°] con una acumulación del 92%, y con un error máximo de 23.2 [°].




Figura 9.49: Histograma del error PWD (Watchkeeper-RNA)




Figura 9.50: Bandas de confianza 95% para testeo de RNA PWD (Caso 2).

Tabla 9.7: Resumen de resultados modelación RNA casos optimizados.

Caso		Alternativas de Arquitectura de RNA (optimizado)				
		5-10-1	5-15-1	5-10-10-1	5-10-15-1	5-15-20-1
Hs	RMS Train (m)	0.225	0.218	0.241	0.214	0.239
	RMS testeo (m)	0.269	0.247	0.273	0.252	0.267
	Ajuste (%)	92.39	93.68	92.36	93.18	92.73
	Desv. Estándar	0.42	0.43	0.43	0.41	0.43
	Iteraciones	207	24	31	28	22
Tp	RMS Train (s)	1.178	1.155	1.209	1.213	1.184
	RMS testeo (s)	1.090	1.275	1.069	1.069	1.166
	Ajuste (%)	84.94	84.66	84.73	84.56	83.82
	Desv. Estándar	1.23	1.29	1.07	1.14	1.28
	Iteraciones	95	414	29	27	90
MWD	RMS Train (°)	5.138	5.13	5.174	5.134	5.138
	RMS testeo (°)	3.692	3.837	3.739	3.740	3.707
	Ajuste (%)	89.93	89.61	89.71	89.93	89.87
	Desv. Estándar	5.70	5.92	5.71	5.79	5.68
	Iteraciones	11878	3122	7784	6813	4104
PWD	RMS Train (°)	6.239	6.216	6.271	6.213	6.059
	RMS testeo (°)	4.015	4.042	3.892	3.903	3.991
	Ajuste (%)	92.42	92.39	92.83	92.90	92.58
	Desv. Estándar	7.42	7.46	7.40	7.46	7.46
	Iteraciones	1908	962	3538	6660	6549
TODOS INCLUIDOS	RMS Train	3.334	3.704	3.209	3.430	3.431
	RMS testeo	2.487	2.674	2.353	2.685	2.669
	Ajuste (%)	88.59	87.11	89.86	87.20	87.34
	Iteraciones	603	680	1574	310	108

La Tabla 9.7 presenta los resultados de las modelaciones neuronales que se utilizaron para obtener el menor error posible entre el dato deseado y el obtenido por la red. Se presentan en un color diferente los mejores ajustes con respecto al valor medido. Puede además apreciarse de la tabla que no todos los valores convergen a un mismo número de iteraciones, alcanzando las 11878 iteraciones para el entrenamiento del MWD, mientras que para el caso de la Hs se llegó al mejor resultado de ajuste a las 24 iteraciones.

La Tabla 9.8 presenta el incremento porcentual que presentaron los parámetros de resumen obtenido con las RNA para las distintas alternativas de topologías (arquitectura) de red con la cantidad de iteraciones optimizadas (buscando el mejor ajuste en el testeo) respecto a los resultados testeados con un número de iteraciones igual para cada alternativa (caso no optimizado).

Tabla 9.8: Incremento del índice de ajuste al optimizar cantidad de iteraciones

	Incrementos Índice de Ajuste [%]				
	5-10-1	5-15-1	5-10-10-1	5-10-15-1	5-15-20-1
Hs	0.18	1.04	1.20	0.42	0.80
Tp	1.51	0.59	0.22	1.06	0.46
MWD	0.77	0.40	0.64	2.96	0.36
PWD	0.09	0.09	0.29	0.31	0.24
Todos Incluidos	4.04	0.37	1.70	0.77	0.94

9.2.4 RESULTADO CON MÉTODO PREDICTIVO ARIMA

Cabe señalar que todas las modelaciones realizadas con ARIMA proyectaron 150 pasos al futuro en la predicción, lo que se traduce a 20 días de testeo. Esta proyección se debió principalmente a la pérdida de precisión en el modelo para reproducir la serie con una extensión mayor de testeo.

Del resultado de la predicción por el método ARIMA para Hs se obtiene un índice de ajuste de 41.4%, con un error máximo de 1.3 [m] y un error medio de 0.7 [m]. (Véase Figura 9.51)

Parámetros modelo ARIMA utilizados:

- Periodos : 39
- Autorregresivo no estacionario : 2
- Autorregresivo estacionario : 2
- Diferencias no estacionarias : 0
- Diferencias estacionarias : 1




Figura 9.51: Predicción método ARIMA para Hs (Watchkeeper-Arica)

Del resultado de la predicción por el método ARIMA para Tp se obtiene un índice de ajuste de 61.49%, con un error máximo de 5.15 [s] y un error medio de 0.97 [s]. (Véase Figura 9.52)

Parámetros modelo ARIMA utilizados:

- Periodos : 41
- Autorregresivo no estacionario : 2
- Autorregresivo estacionario : 0
- Diferencias no estacionarias : 0
- Diferencias estacionarias : 1




Figura 9.52: Predicción método ARIMA para Tp (Watchkeeper-Arica)

Del resultado de la predicción por el método ARIMA para MDW se obtiene un índice de ajuste de 36.28%, con un error máximo de 15.2 [°] y un error medio de 7.8 [°]. (Véase Figura 9.53)

Parámetros modelo ARIMA utilizados:

- Periodos : 38
- Autorregresivo no estacionario : 5
- Autorregresivo estacionario : 0
- Diferencias no estacionarias : 0
- Diferencias estacionarias : 1




Figura 9.53: Predicción método ARIMA para MWD (Watchkeeper-Arica)

Del resultado de la predicción por el método ARIMA para PDW se obtiene un índice de ajuste de 49.18%, con un error máximo de 39.77 [°] y un error medio de 14.35 [°]. (Véase Figura 9.54)

Parámetros modelo ARIMA utilizados:

- Periodos : 68
- Autorregresivo no estacionario : 3
- Autorregresivo estacionario : 0
- Diferencias no estacionarias : 0
- Diferencias estacionarias : 2




Figura 9.54: Predicción método ARIMA para PWD (Watchkeeper-Arica)

Tabla 9.9: Resumen de resultados para predicciones RNA y ARIMA

Parámetros	RNA		ARIMA	
	RMS	Ajuste	RMS	Ajuste
Hs	0,27	93,68%	0,76	41,37%
Tp	1,07	84,94%	1,44	61,49%
MWD	3,74	89,93%	17,17	49,18%
PWD	7,40	92,90%	8,75	36,28%

9.2.5 COMENTARIOS Y CONCLUSIONES

Para el entrenamiento de este caso se utilizaron dos metodologías, en la primera se entrenaron redes con el objetivo de hallar todos los parámetros del oleaje de forma conjunta correlación óptima frente al valor deseado. Y también a manera de ejercicio se entrenaron redes neuronales con parámetros de resumen de forma aislada como salida deseada, es decir, como datos de entrada se utilizó los 5 parámetros obtenidos del NOAA y como salida sólo tenemos un parámetro ya sea Hs, Tp, MWD o PWD.

Del ejercicio de comparación de los resultados bajo el paro de iteraciones a un mismo tiempo y otro parando según el mejor punto de correlaciones, se puede concluir que no todos los valores convergen a un mismo número de iteraciones, alcanzando por ejemplo, las 11878 iteraciones para el entrenamiento del MWD, mientras que para el caso de la Hs se llegó al mejor resultado de ajuste a las 24 iteraciones. Lo que significa que mientras un parámetro puede conseguir un mejor ajuste a mayor cantidad de iteraciones, otro parámetro puede estar mermando sus resultados, por lo que se recomienda un entrenamiento por separado de cada parámetro, manteniendo siempre el mismo inalterable los parámetros de entrada. Con este cambio se obtuvieron mejores correlaciones aumentando en hasta 2.57 puntos porcentuales las correlaciones (Tabla 9.8) para el caso específico de la Dirección media del oleaje.

Comparando los resultados de la RNA versus los resultados obtenidos por los pronósticos del método ARIMA, las redes obtienen una gran ventaja en la predicción (véase Tabla 9.9) quedando reflejado en los bajos errores en los valores de RMS del que se puede destacar el bajo error para Hs de sólo 0.27 [m]. Además las redes neuronales por su carácter no lineal, obtienen mejores estimaciones para mayores extensiones temporales en cambio el método ARIMA pierde precisión a medida que se pretende predecir más hacia el futuro.

9.3 CASO 3: HERRAMIENTA DE CONSTRUCCIÓN DE ESPECTROS SINTÉTICOS POR MEDIO DE RNA

9.3.1 RESEÑA DEL CASO

Con el fin de caracterizar la energía del oleaje, se debe procurar tener un dato más completo que sólo la utilización de parámetros de resumen que sesgan la real composición del oleaje, como por ejemplo; las bimodalidades presente en un estado de mar. Para esto en el presente caso se evaluará el comportamiento de las redes neuronales frente al problema de la generación de espectros sintéticos a partir de parámetros de resumen. Principalmente en la reproducción de las no-linealidades presentadas por los espectros cuya composición presente casos de bimodalidades o trimodalidades, qué para las técnicas actuales, como JONSWAP, TMA, Pierson-Moskowitz (Y. Goda, 1999), es casi imposible de reproducir.

Set de entrenamiento: 20 - 11 - 2000 12:00 al 31 - 12 - 2005 21:00

Set de testeo : 01 - 01 - 2006 00:00 al 31 - 12 - 2006 18:00




Figura 9.55: Nodo Extracción de Datos (Zona Central, Chile)

En la Figura 9.55 se puede apreciar la ubicación geográfica del nodo de extracción de datos espectral y parámetros de resumen de la ola, útiles para el desarrollo del presente caso. Las coordenadas geográficas serán expuestas a continuación:

Coordenadas Nodo : 35° 00' 00.00" S

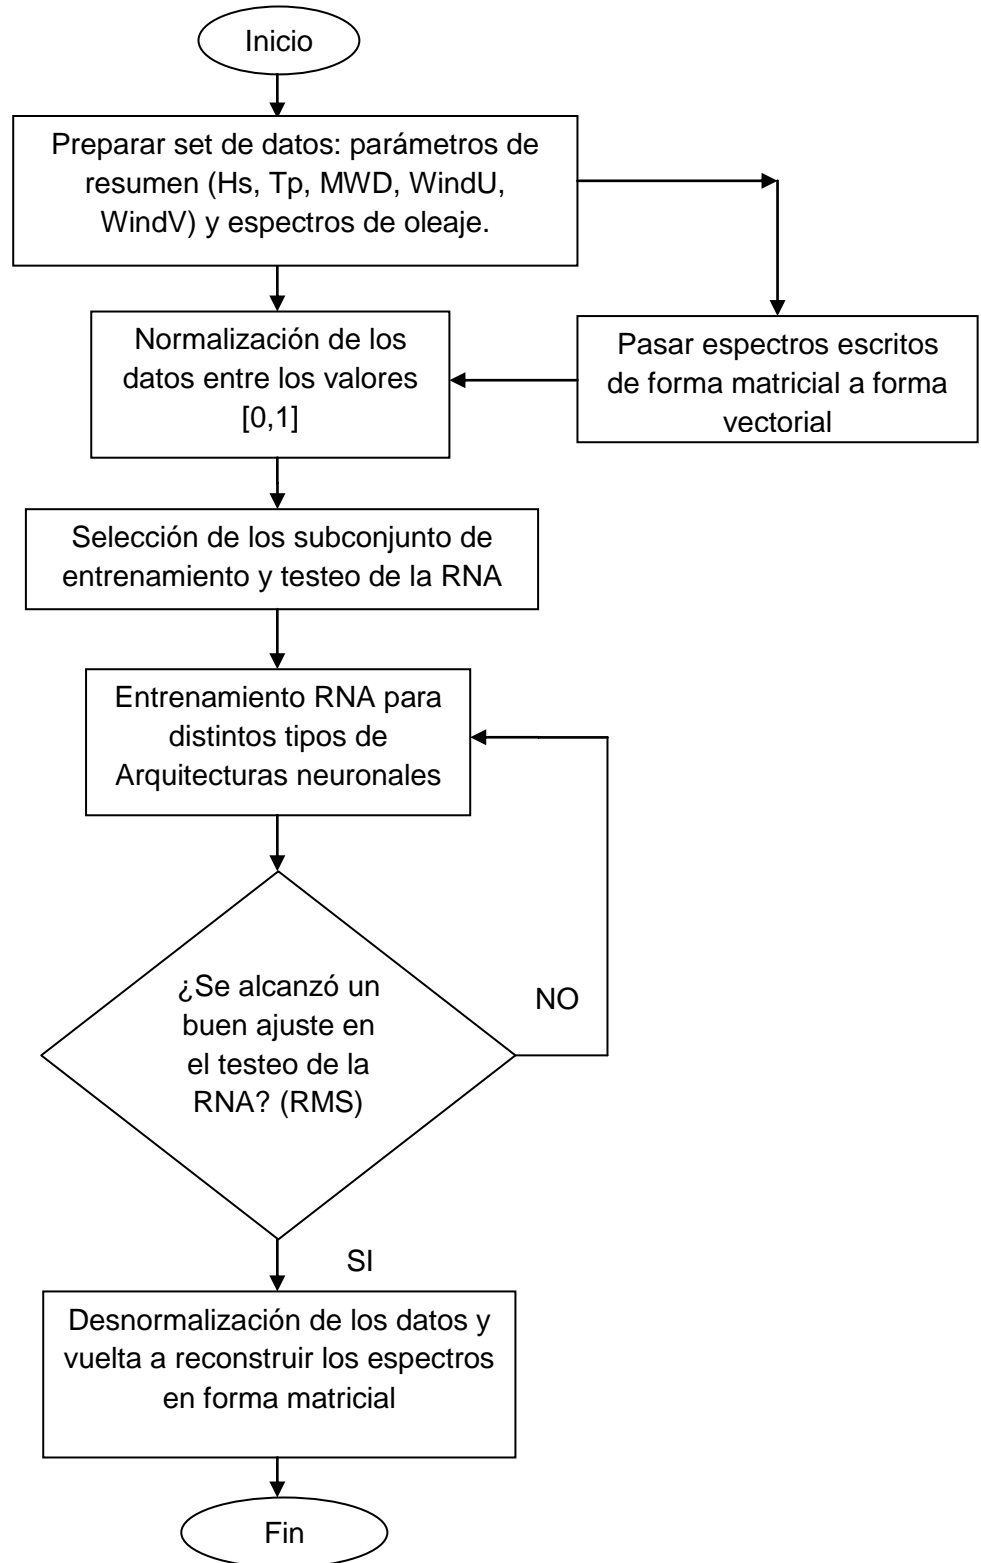
73° 00' 00.00" W

9.3.2 PROCEDIMIENTO DE ENTRENAMIENTO

Para entrenar las RNA se deben realizar una serie de pasos antes, durante y posteriores a las modelaciones, los cuales serán descritos a continuación:

- Los espectros están escritos de manera matricial (frecuencias versus direcciones), y para el entrenamiento de la red se requiere trabajar de manera vectorial, por lo que se debe pasar esta matriz de dispersión de energía a un vector de vectores. Lo que permitirá realizar de manera correcta la modelación.
- Puesto que se está trabajando con una gran cantidad de datos, es recomendable normalizarlos (en este caso como se utilizó una función del tipo logística, por entregar resultados de tipo continuos y además de ser la mayormente utilizada en casos de predicción, fue necesario estandarizar los valores entre los rangos 0 y 1), esto con el fin de reducir los tiempos de modelación.
- Se sensibiliza los tipos de redes, principalmente modificando su arquitectura, como aumento o disminuciones en las neuronas de la capa oculta, también aumentando o disminuyendo capas ocultas de la red.
- Una vez que se logra optimizar la arquitectura de la red, y obtenidos los resultados tanto del entrenamiento como del testeo, estos se desnormalizan y se obtienen la correlación real resultante entre los espectros obtenidos con la RNA y los medidos en campo.
- Por último se vuelven a pasar de vectores a matrices y se grafican casos al azar para verificar de manera gráfica las similitudes y diferencias entre un espectro generado por la red y uno tomado en campo.
- Para asegurar el correcto aprendizaje y buen funcionamiento de la arquitectura de la red escogida por sus buenos resultados, la literatura especializada en RNA (Intelligent Data Analysis - M. Berthold & D. Hand, 2007) recomienda una validación cruzada, y para esto se entrena nuevamente la red de resultados óptimos cambiando los datos de entrenamiento por los últimos 5 años y testeando con el primer año, al contrario de cómo se había entrenado en los modelos previos.

9.3.3 METODOLOGÍA DEL ENTRENAMIENTO NEURONAL



9.3.4 RESULTADOS

9.3.4.1 ARQUITECTURAS REALIZADAS

Las alternativas realizadas se enumeran a continuación:

- 1) Una capa oculta con 250 neuronas en ella.
- 2) Una capa oculta con 300 neuronas en ella.
- 3) Una capa oculta con 350 neuronas en ella.
- 4) Dos capas ocultas con 250 neuronas en la primera y 400 neuronas en la segunda.

Tabla 9.10: Resumen de resultados para alternativas realizadas

Alternativa	RMS Entrenamiento	RMS Testeo	Iteraciones	Tiempo de Cómputo
1	0.01341	0.02534	44	15h 45m
2	0.01414	0.02556	99	35h 23m
3	0.01330	0.02523	46	18h 30m
4	0.11457	0.11457	97	84h 06m

Los tiempos de cómputo obtenidos para las modelaciones son en referencia a un PC Intel Pentium Dual-Core 3.0 GHz con 2 GB de memoria RAM con un sistema operativo de 32 Bits.

De los resultados antes expuestos en la Tabla 9.10 se selecciona finalmente la opción de arquitectura de 350 neuronas con una única capa oculta, esto principalmente por presentar dos ventajas:

- La primera se debe a que presentó los menores errores en la fase de entrenamiento como en la fase de testeo.
- Y la segunda, sus resultados convergieron en menor cantidad de iteraciones, lo que se traduce a menores tiempos computacionales.

9.3.4.2 SET DE ENTRENAMIENTO

La Figura 9.56 y Figura 9.57 presenta en línea negra los datos medidos y la línea roja los modelados por la red, en particular esta visualización representa la modelación de un bin, considerando que un espectro está conformado por una matriz de 24 direcciones por 25 frecuencias, lo que resultan 600 bin por cada espectro.




Figura 9.56: Comparación entre un bin medido (bin 355) y otro modelado para 5 años de entrenamiento (Alta energía asociada)




Figura 9.57: Comparación entre un bin medido (bin 407) y otro modelado para 5 años de entrenamiento (Alta energía asociada)

La Figura 9.58 y Figura 9.59 similar al caso anterior representan el ajuste entre un bin para la totalidad de los espectros utilizados para el entrenamiento de la red, la diferencia de las anteriores figuras radica en que estas gráficas presentan menor cantidad de energía asociada y aun así se obtiene un buen ajuste entre el bin medido y el producido por la red neuronal.




Figura 9.58: Comparación entre un bin medido (bin 438) y otro modelado para 5 años de entrenamiento (Baja energía asociada)




Figura 9.59: Comparación entre un bin medido (bin 287) y otro modelado para 5 años de entrenamiento (Baja energía asociada)

9.3.4.3 SET DE TESTEO

En la Figura 9.60 y Figura 9.61 se observan gráficos de los resultados del testeo para el equivalente de un año de datos no incluidos en el set de entrenamiento de la RNA el cual consta de 5 años de extensión temporal, con datos registrados cada tres horas (correspondiente a un estado de mar).




Figura 9.60: Comparación entre un bin medido (bin 354) y otro modelado para 1 año de entrenamiento




Figura 9.61: Comparación entre un bin medido (bin 406) y otro modelado para 1 año de entrenamiento

La Figura 9.62 y Figura 9.63 similar al caso anterior representan el ajuste entre un bin para la totalidad de los espectros utilizados para el testeo de la red, la diferencia de las anteriores figuras radica en que estas gráficas presentan menor cantidad de energía asociada y aun así se obtiene un buen ajuste entre el bin medido y el producido por la red neuronal.




Figura 9.62: Comparación entre un bin medido (bin 241) y otro modelado para 1 año de entrenamiento




Figura 9.63: Comparación entre un bin medido (bin 312) y otro modelado para 1 año de entrenamiento

9.3.4.4 COMPARACIÓN ENTRE ESPECTROS SINTÉTICOS Y MEDIDOS.

La Figura 9.64 muestra la comparación entre un espectro medido (izquierda) mientras que el de la derecha corresponde a un espectro sintético generado por la red neuronal. Este espectro en particular se obtuvo el día 4 de Diciembre del 2006 a las 03:00 horas. Se presenta una correlación del 99.01% y un R2 del 98.18%. (Véase Anexo en la Figura 13.5)




Figura 9.64: Comparación entre espectro medido con espectro sintético

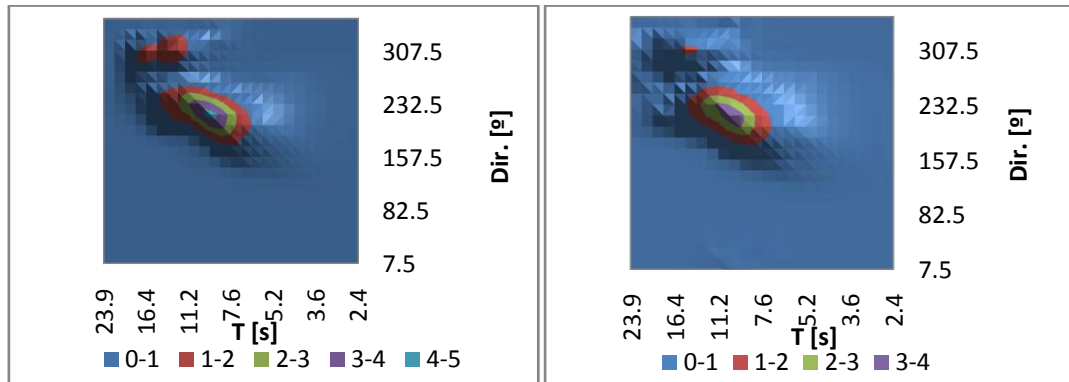


Figura 9.65: Comparación entre espectro medido con espectro sintético (caso bimodal)

En la Figura 9.65 se presenta la comparación entre dos espectros el de la izquierda el espectro medido y el de la derecha correspondiente al espectro sintético desarrollado por la RNA (30 de Enero del 2006 a las 15:00 horas). Se puede apreciar de este ejemplo la formación y caracterización de una particularidad de los espectros de oleaje, la bimodalidad. Esta es representada también por la RNA tanto es su distribución de frecuencia como en su dirección de aparición. Cabe señalar además que en su generalidad los espectros sintéticos obtenidos, no representan con exactitud la acumulación de energía en los peak, produciéndose una dispersión lateral de energía. Esto puede deberse principalmente a la limitada cantidad de iteraciones que se debieron realizar para el entrenamiento de la red. Para este caso en puntual se obtuvieron correlaciones de 97.58% y de un R2 de 95.21%. (Véase Anexo en la Figura 13.6)

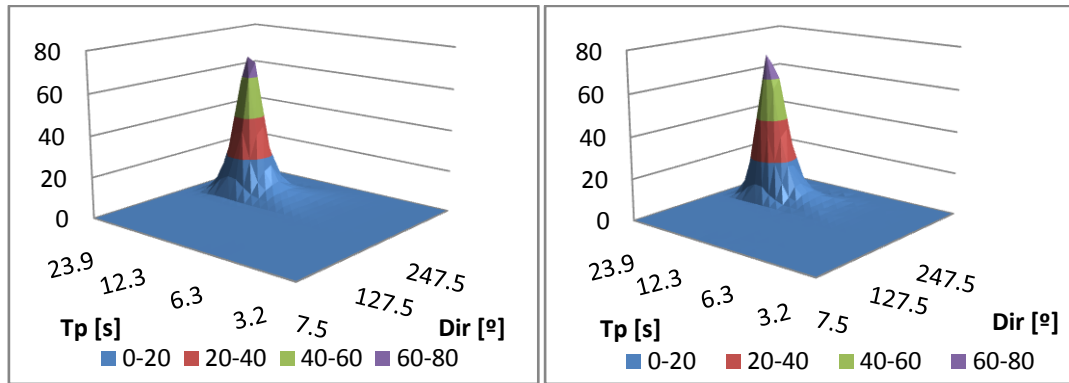


Figura 9.66: Comparación entre espectro medido con espectro sintético (caso espectro con mayor energía)

La Figura 9.66 muestra la comparación de los espectros correspondiente al 20 de Abril 2006 a las 12:00 horas. Lo relevante de esta muestra se encuentra en la cantidad de energía asociada al espectro, que a diferencia de los anteriores, este presenta un incremento considerable, y es representado sin problemas para la RNA. Posee una correlación de 97.24% y un ajuste R2 de 94.56%. (Véase Anexo en la Figura 13.7)




Figura 9.67: Comparación entre espectro medido con espectro sintético (caso bimodal)

En la Figura 9.67 se presenta la comparación entre dos espectros el de la izquierda el espectro medido y el de la derecha correspondiente al espectro sintético desarrollado por la RNA (24 de Noviembre del 2006 a las 06:00 horas). Se puede apreciar de este ejemplo la formación y caracterización de una particularidad de los espectros de oleaje, la bimodalidad, en este caso producido en el dominio de las frecuencias. Esta es representada también por la RNA tanto es su distribución de frecuencia como en su dirección de aparición. Para este espectro de presenta una correlación del 96.86% y un R2 de 93.81%. (Véase Anexo en la Figura 13.8)

En la Figura 9.68 se puede apreciar (espectro tomado el 13 de Mayo del 2006 a las 06:00 horas) otro espectro con características bimodales, con la diferencia que la energía

asociada a este es mucho menor que los anteriores ejemplos llegando a un peak de $4.2 \text{ m}^2 \cdot \text{s}$. (Véase Anexo en la Figura 13.9)

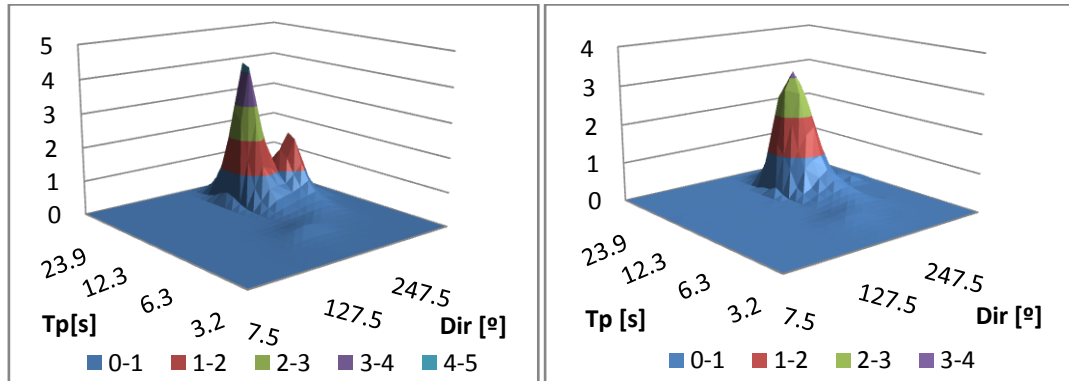


Figura 9.68: Comparación entre espectro medido con espectro sintético (caso baja correlación)

El espectro obtenido de la RNA muestra un pobre ajuste en el peak de energía, además el segundo peak proveniente de la dirección $277.5 [^\circ]$ no se alcanzó a formar, resultando en definitiva un espectro unimodal. Esto puede deberse a que los efectos no lineales, preponderantes en espectros de baja energía, sumados a características de tipo bimodales son tan puntuales, que el reconocimiento de patrones en la fase de entrenamiento, no los tomó en consideración, advirtiendo que no eran datos confiables y asumiéndolos como particulares poco relevantes para la generalización.

Para este caso puntual se obtuvieron correlaciones de 83.40% y de un R2 de 69.56%.

En la Figura 9.69 se puede apreciar (espectro tomado el 16 de Junio del 2006 a las 15:00 horas) que el espectro medido (izquierda) presenta características trimodales, tanto en el dominio de las direcciones como en el dominio de la frecuencia, haciendo de este un caso muy particular y por ende muy difícil de reproducir para la red neuronal, tanto por su alto porcentaje de no linealidad asociada como por su baja frecuencia de aparición entre los casos entrenamos. Por lo que su símil generado con la red no alcanza a representar de manera adecuada el segundo y tercer peak, además de quedar corto en el peak de energía. Obteniéndose así una correlación de 76.85% y un R2 de 59.06% que reflejan el bajo ajuste logrado para este tipo de casos. (Véase Anexo en la Figura 13.10)




Figura 9.69: Comparación entre espectro medido con espectro sintético (baja correlación, espectro trimodal).

9.3.4.5 VALIDACIÓN CRUZADA

Esta técnica se utiliza para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre datos de entrenamiento y prueba. Consiste en repetir y calcular la media aritmética obtenida de los distintos conjuntos de entrenamiento y testeo de un modelo. Se utiliza en entornos donde el objetivo principal es la predicción y/o correlación. Es una técnica muy utilizada en proyectos de inteligencia artificial para validar modelos generados.

Para este caso se utilizará como set de entrenamiento los últimos 5 años y testeando con el primer año, completamente al contrario del caso estudiado anteriormente.

A continuación y a modo de ejemplo se presentan dos gráficos (Figura 9.70 y Figura 9.71) se muestran los ajustes logrados entre los valores para un bin particular del espectro medido versus el entregado por la RNA para el set de testeo.




Figura 9.70: Salida de comparación entre un bin medido (bin293) y otro modelado para 1 año de testeo (Validación cruzada)




Figura 9.71: Salida de comparación entre un bin medido (bin356) y otro modelado para 1 año de testeo (Validación cruzada)

La correlación presentada por este caso es de 89.70% con un R2 de 81.07% lo que promediado con el resultado anterior (con el testeo para el último año), da un coeficiente de correlación de 90.67 con un R2 82.92%. Este valor representa a la validación cruzada, de lo que se concluye que la red es capaz de generalizar no importando el orden de los set de entrenamiento y testeo.

9.3.5 COMPARACIÓN CON ESPECTRO SINTÉTICO JONSWAP

Los espectros sintéticos generados de por la herramienta JONSWAP para el año de testeo se utiliza en esta tesis a modo de comparación con los resultados de la Red neuronal utilizada para este caso. Quedando finalmente una correlación de 80.28% y un R2 de 64.45% con respecto al espectro medido y un RMS de 0.798 [m^2/s].

9.3.6 COMENTARIOS Y CONCLUSIONES

Los tiempos de entrenamiento dependerán básicamente de la cantidad de información que se desee entrenar en este caso en particular los parámetros de resumen que sirven como neuronas de entrada son 21, y las neuronas de salidas son 600 correspondiente a un espectro de densidad de energía de 24 direcciones por 25 frecuencias, y también del tipo de arquitectura que se quiera modelar, pero un promedio de tiempo de entrenamiento ronda por el día a los dos días, en un PC Intel Dual-Core 3.0GHz con 2GB en RAM con SO de 32 Bits, para que converja en un valor razonablemente bueno (sobre el 85% de ajuste con respecto al dato medido). Existía la posibilidad de reducir dicha cantidad acotando los rangos de dirección y frecuencias menos relevantes, pero esta idea fue descartada, debido a que al hacer esto se perdían datos significativos del tipo Sea quedándonos sólo con resultados válidos para oleaje del tipo Swell.

Si bien los tiempos de entrenamientos son altos, los tiempos de testeo son casi instantáneos. Permitiendo considerables disminuciones en los tiempo de cómputos frente a otro tipo de metodologías de construcción de espectros sintéticos.

La literatura existente de redes neuronales afirma que para casos en donde las no-linealidades son significativas, se recomienda la utilización de 2 capas ocultas, puesto la primera sería la encargada de capturar los mínimos locales y la segunda para obtener los mínimos de errores globales (S. Haykin, 1999). En este caso en particular esa afirmación no se cumple, a través de las pruebas realizadas se pudo observar exagerados tiempos de entrenamientos y pobres disminuciones del error, sin conseguir converger a un valor cercano al deseado. Esto se pudo deber principalmente a la gran cantidad de información contenida por cada espectro y si a eso le sumamos que los registros están medidos cada 3 horas por 5 años. La cantidad de información puede llegar a ser abrumadora y con un costo en tiempos de cómputo muy alto (sobre 7 a 10 días) para obtener buenos resultados utilizando dos capas ocultas en la arquitectura de la red.

La arquitectura que presentó los mejores resultados en la disminución del error y también las mejores correlaciones entre la salida del modelo y los espectros medidos, fue la tercera correspondiente a la red de 350 neuronas en la capa oculta. Presentando una correlación promedio para el testeo de la red de 91.63% y un R2 de 84.76% con un RMS de 0.0133 [m²s] para el entrenamiento y con un RMS de 0.02523 [m²s] para el testeo con respecto al valor medido.

Finalmente comparando los resultados con los obtenidos con la formulación JONSWAP, las redes neuronales obtienen una superioridad de más de un 10% en el coeficiente de correlación, además de poder reproducir bimodalidades del oleaje. Además el RMS obtenido de JONSWAP fue de 0.798 [m²s] versus los 0.025 [m²s] de las redes.

10 CONCLUSIONES Y COMENTARIOS FINALES

En un principio la tesis fue concebida como una herramienta que prestara una manera de mejorar los resultados buscando, a través de las redes neuronales, una forma de correlacionar los datos obtenidos de, por ejemplo, NOAA a los parámetros del oleaje aportados de la Boya TRIAXYS instalada en Lebu y Valparaíso por el proyecto en el que se enmarca esta investigación, el objetivo de esto es que a partir de una cierta cantidad de datos se pudieran generar, a través de la larga data disponible en NOAA, correlaciones y extender nuestra data para la investigación del proyecto. Así mismo con esta información en parámetros de resumen crear una herramienta capaz de construir espectros de oleaje (espectros sintéticos), pero con una alta relación con la realidad, reproduciendo bimodalidades características del oleaje y otros fenómenos propios de la no linealidad del oleaje como dispersiones laterales, etc.

Al presentar algunos inconvenientes los instrumentos de medición, como el corte del sistema de fondeo de la boya TRIAXYS, se utilizaron resultados de modelos de generación global del oleaje o set de oleaje proporcionado por el SHOA. O bien contar con set de datos reducidos en escala temporal (como el caso de Lebu). Pero cabe señalar que si bien se incurre en un error controlado, esta investigación apunta a la factibilidad de usar la herramienta de las redes neuronales artificiales para el estudio de este proyecto como la predicción, correlación y construcción de espectros sintéticos del oleaje.

Con los resultados expuestos en la investigación se puede apreciar que existe una relación directamente proporcional entre la extensión temporal de los set de datos con los resultados arrojados por los entrenamientos con las redes neuronales. Esto quiere decir que en los casos donde se disponía de largas datas temporales los resultados están bien ajustados a los datos medidos en campo, mientras el caso que disponía sólo dos meses de registros no presentó resultados adecuados. Sin embargo, y pese a lo reducida que fuese la data, se obtuvieron mejoras respecto de la condición inicial y también comparativamente con otras metodologías de predicción (ARIMA).

También de los resultados, en especial de los histogramas del error presentados, se puede apreciar que la mayor acumulación de los errores se encuentra en torno a valores de RMS bajos lo que significa que las redes se ajustan bien a las necesidades de predicción o correlación con respecto a los valores medidos.

De lo anterior se concluye que finalmente por los resultados obtenidos en la investigación es completamente factible caracterizar, predecir y correlacionar el oleaje por medio de las redes neuronales siempre y cuando se cuente con una data de oleaje aceptable, en términos de extensión temporal, para realizar los entrenamientos de la red.

Como tarea para una futura investigación se propone materializar una herramienta neuronal que no tenga las características de caja negra en su proceso, e implementar la metodología de las llamadas cajas grises en el ámbito de las Redes Neuronales Artificiales, con el fin de mejorar los resultados obtenidos a partir de ecuaciones matemáticas verificadas por la comunidad científica. Estas cajas grises son capaces por medio de la adecuación de los parámetros libres de las formulaciones mejorar sus resultados y adaptarlos para las condiciones de las costas chilenas. Específicamente para el caso de la formulación de JONSWAP desarrolla para la construcción de espectros sintéticos para mares del norte.

11 GLOSARIO

ADCP : Acoustic Doppler Current Profiler. Perfilador de corrientes que utiliza métodos acústico Doppler.

AGUAS PROFUNDAS : Profundidad relativa menor a 0.05

AGUAS SOMERAS : Profundidad relativa mayor a 0.5

ALTURA SIGNIFICATIVA : Es un parámetro estadístico de la altura de ola, obtenido mediante el promedio del tercio superior del set de oleaje.

ARIMA : AutoRegressive Integrated Moving Average. Modelo estadístico que utiliza variaciones y regresiones de datos estadísticos con el fin de encontrar patrones para una predicción al futuro.

BACKPROPAGATION : Es un algoritmo de aprendizaje supervisado que se usa para entrenar redes neuronales artificiales mediante la reducción del error por medio de una retropropagación del error hacia atrás.

BIMODALIDAD OLEAJE : Espectro de oleaje que presenta direcciones distintas y en frecuencias distintas al mismo tiempo. Diferenciado 2 picos de energías bien diferenciados.

CAPA OCULTA : Se refiere a la capa que contiene a las neuronas, dentro de las redes neuronales, que no corresponden a las de entrada ni salida de la red.

CÓDIGO LIBRE : Es el término con el que se conoce al software distribuido y desarrollado libremente.

ERGÓDICO : Se define como un proceso estacionario. Esto quiere decir que sus características se mantienen constantes con el avance del tiempo.

ESPECTRO ENERGÉTICO : Es una matriz que agrupa la energía proveniente en dirección y frecuencia para un estado de mar.

ESPECTRO SINTÉTICO : Es aquel espectro de densidad energética construido a partir de parámetros de resumen de la ola.

ESTADO DE MAR : Es el periodo de medición (**e.g.** entre 1 a 3 horas) en el cual se caracteriza el oleaje por medio de un espectro de densidad energética. Además se asume que las condiciones externas que influyen en él permanecen constantes durante un tiempo determinado.

FUNCIÓN DE ACTIVACIÓN : Determina el estado de activación actual de la neurona en base al potencial resultante y al estado de activación anterior de la neurona.

MWD : Abreviación de Mean Wave Direction. Dirección media del oleaje. Es la dirección de procedencia media de las olas medidas en el periodo de registro.

NEURONA : Dentro de la rama de la inteligencia artificial, una neurona es una unidad básica de procesamiento a la que se le asigna una función de activación.

NOAA : National Oceanic and Atmospheric Administration. Agencia federal de los EEUU. Encargada del monitoreo e investigación de las variables atmosféricas y oceanográficas.

PARÁMETROS RESUMEN : Son parámetros útiles para el diseño de una obra portuaria (ej. Hs, Tp, MWD, PWD, etc.). Estos parámetros son obtenidos desde los espectros de densidades del oleaje por medio del cálculo de los momentos espectrales.

PERCEPTRÓN : Es un tipo de red neuronal artificial desarrollado por Frank Rosenblatt, también puede entenderse como perceptrón la neurona artificial y unidad básica de inferencia en forma de discriminador lineal, que constituye este modelo de red neuronal artificial. Esto debido a que el perceptrón puede usarse como neurona dentro de un perceptrón más grande u otro tipo de red neuronal artificial.

PERIODO DE OLA : Tiempo medido entre dos valles o dos crestas de una ola.

PERIODO PEAK : Periodo de ola obtenido por medio de la frecuencia que concentra la mayor cantidad de energía dentro de espectro

PESO SINÁPTICO : El peso sináptico w_{ij} se define como la fuerza de una conexión sináptica entre dos neuronas, la neurona presináptica i y la neurona postsináptica j . Los pesos sinápticos pueden tomar valores positivos, negativos o cero. En caso de una entrada positiva, un peso positivo actúa como excitador, mientras que un peso negativo actúa como inhibidor. En caso de que el peso sea cero, no existe comunicación entre el par de neuronas.

PROCESO ESTOCÁSTICO : Secuencias caracterizadas por propiedades estadísticas. Es la abstracción matemática de un proceso empírico, cuyo desarrollo se encuentra gobernado por leyes de probabilidad. Según Goda, se refiere a un conjunto de variables tales que las cantidades en cuestión varían azarosamente con el tiempo.

PROFUNDIDAD RELATIVA : Es la razón existente entre la longitud de la ola y la profundidad en el lugar observado

PWD : Abreviación de Peak Wave Direction. Dirección peak del oleaje. Determinada por medio de la identificación del pico de energía dentro del espectro de densidad energética de la ola.

RNA : Red neuronal artificial o en inglés Artificial Neural Network (ANN). Modelo idealizado y simplificado del proceso neuronal biológico. Campo perteneciente a la Inteligencia Artificial (IA).

RMS : RMS (Root Mean Square) el valor medio cuadrático se utiliza un indicador del error. Y es una medida estadística de la magnitud de una cantidad variable.

SEA : Oleaje formado por generación local del viento, caracterizado por periodos de oleaje cortos (menos de 6 segundos) y gran dispersión direccional. Es totalmente caótico y no cuenta con alturas y periodos bien definidos.

SERIE DE FOURIER : Es una serie infinita que converge puntualmente a una función periódica y continua a trozos. Es empleado para analizar funciones periódicas a través de la descomposición de dicha función en una suma infinita de funciones senoidales mucho más simples.

SERIE TEMPORAL : Muestra de oleaje. Conjunto de valores de la elevación de la superficie libre del mar ordenado con respecto al tiempo.

SET ENTRENAMIENTO : Set utilizado para el entrenamiento de la red neuronal. Utilizado para el reconocimiento de los patrones de la serie.

SET TESTEO : Set utilizado para el testeo de la red, este set es solo para comparar los resultados de la red, por lo tanto estos datos nunca fueron entrenados en la Red Neuronal.

SINAPSIS : Es la conexión entre neuronas de una capa y otra. Encargada de transportar la información de una neurona a otra.

SPREADING DIRECCIONAL: Es la dispersión de energía en el dominio de las direcciones en un espectro de oleaje.

SURFACE : Superficie libre del mar.

SWELL : Oleaje desarrollado de formación lejana, la que ha permitido el ordenamiento de sus direcciones y periodos, presenta características de periodos largos y alturas elevadas de oleaje. Los frentes de ola están bien alineados. Muestra alturas y periodos bien definidos.

TASA DE APRENDIZAJE : Se puede definir como un factor de paso que permite acelerar o disminuir los tiempos de entrenamientos de la red. Pero teniendo en cuenta que con valores altos para este factor se pueden lograr pobres resultados de entrenamiento.

TRANSFERENCIA OLAJE: Transferir las características del oleaje de aguas profundas a aguas someras mediante coeficientes de agitación y dirección.

TRIAXYS : Boya TRIAXYS utilizada para medir las características tanto de densidad espectral como de parámetros de resumen del oleaje mediante 3 acelerómetros, un giroscopio, y un compás fluctuantes.

UNDIMOTRIZ : Mecanismo que utiliza el movimiento de las olas.

VALIDACIÓN CRUZADA : Método de validación muy utilizado en las áreas de RNA para determinar el grado.

WATCHKEEPER : Boya de medición in-situ del oleaje, utilizada para obtener tanto espectros de densidad energética, como parámetros de resumen del oleaje.

WAVEWATCH III : Modelos de generación del oleaje a escala global, perteneciente a NOAA.

ZERO-UPCROSSING : Es una técnica matemática estadística que permite definir una ola como el perfil entre dos cruces consecutivos de la superficie libre por el cero hacia arriba.

ZERO-DOWNCROSSING : Es una técnica matemática estadística que permite definir una ola como el perfil entre dos cruces consecutivos de la superficie libre por el cero hacia abajo.

12 REFERENCIAS

- Amalia A. Catálfamo. Redes Neuronales aplicadas a señales sonoras obtenidas de un sonar.
- H.K. Chang, W.A. Chien (2005). Neural network with multi-trend simulating transfer function for forecasting typhoon wave.
- Juan A. Pérez Ortiz (2002). Modelos predictivos basados en redes neuronales recurrentes de tiempo discreto.
- Shailesh Namekar, **et al** (2009). Neural network for tsunami and runup forecast.
- M.C. Deo (2010). Artificial neural networks in coastal and ocean engineering.
- Joanna Collantes D. (2001). Predicción con Redes Neuronales: Comparación con las metodologías de Box y Jenkins.
- Luis F. Bertona (2005). Entrenamiento de Redes Neuronales basado en algoritmos evolutivos.
- Hendrik L. Tolman, Vladimir M. Krasnopolsky, Dmitry V. Chalikov (2004). Neural network approximations for nonlinear interactions in wind wave spectra: direct mapping for wind seas in deep water.
- Nicolau, F. (2006). Comparación metodológica de transferencias de oleaje.
- Yoshimi Goda (1999). A comparative review on the functional forms of directional wave spectrum.
- Cort J. Willmott **et al.** (2011). A refined index of model performance
- Andries P. Engelbrecht (2002). Computational Intelligence.
- Mohamed A. Mohandes, Shafiqur Rehman and Talal O. Halawan (1997). A neural networks approach for wind speed prediction
- Robert J. Abraham, Pauline E. Kneale & Linda M. See (2004). Neural Networks for hydrological modeling.
- Anurag More, M.C. Deo. Forecasting wind with neural networks.

- S. Haykin, (1999). Neural Networks: A Comprehensive Foundation.
- Raúl González Duque. Python para todos.
- M. Berthold & D. Hand, 2007. Intelligent data analysis.
- Stanislaw R. Massel (1996). Ocean surface waves: their physics and prediction.
- www.python.org, (Agosto 2011). User manual Python.
- S.N. Londhe & Vijay Panchang (2006). One-Day wave forecasts based on Artificial Neural Networks.
- S. Mandal **et al.** (2004). Neural Networks for estimation of ocean wave parameters.
- B. Bhattacharya **et al.** (2003). Neural Networks in reconstructing missing wave data in sedimentation modelling.
- <http://dit.ipg.pt/MBP>, (Septiembre 2011). User manual Multiple Backpropagation.
- Reena Naithani (2006). Estimation of wave spectral shapes using ANN.
- Eduardo Monsalve, (2009). Desarrollo e implementación de modelo de transferencia espectral de oleaje en bahía de Valparaíso.
- SWAN User manual, (2011). Delft University of Technology.
- Axys Technologies Inc., (2010), User manual AXYS Data Management System
- Axys Technologies Inc., (2010), Installation and setup manual, AXYS Data Management System
- Teledyne RDI Instrument, (2010), User's Guide WavesMon v3.07 (ADCP)
- [Ftp://polar.ncep.noaa.gov/pub/history/waves](ftp://polar.ncep.noaa.gov/pub/history/waves)

13 ANEXOS

13.1 ANEXO FFT LENGTH (5 ESTADOS DE MAR)

Sensibilización realizada a la herramienta de procesamiento de datos del ADCP para 5 estados de mar. Para la determinación de las mejores alternativas de cálculo, para cada uno de los parámetros de forma independiente.

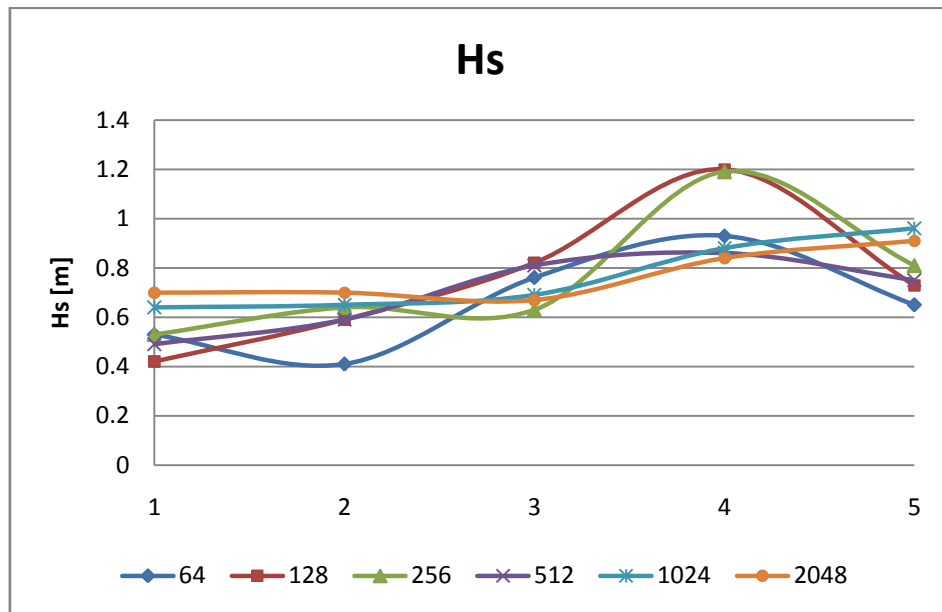


Figura 13.1: Sensibilización de H_s para distintos FFT Length

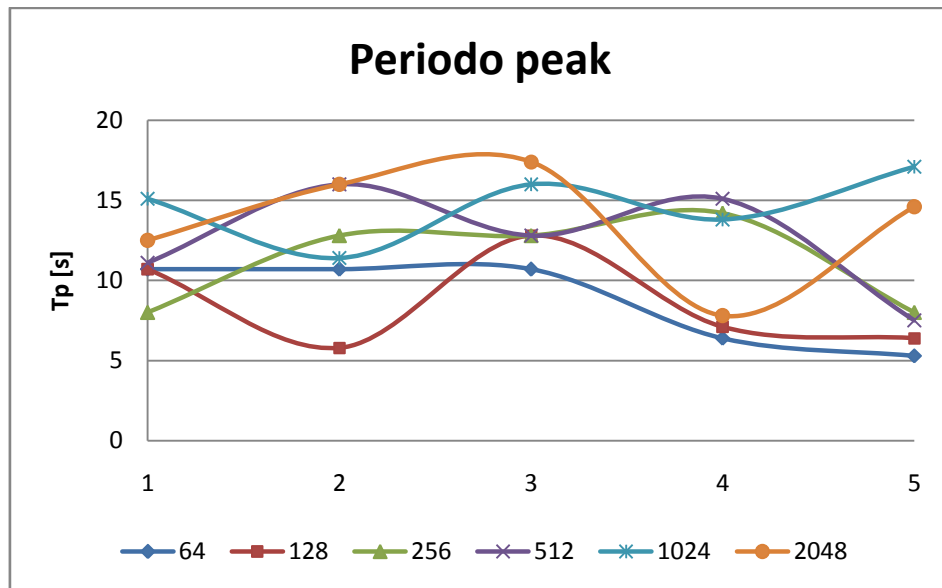


Figura 13.2: Sensibilización de T_p para distintos FFT Length

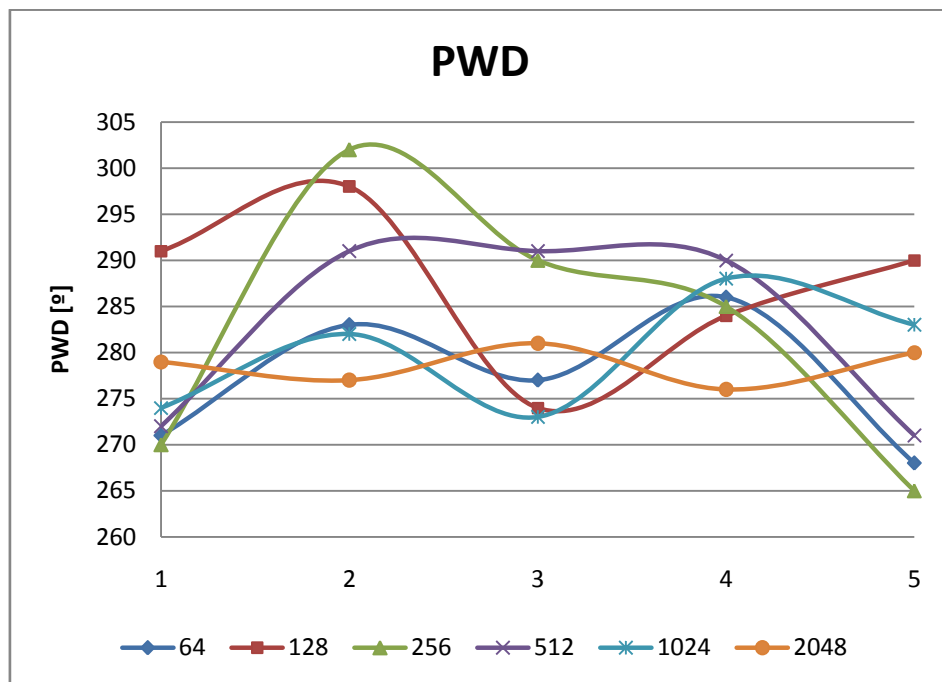


Figura 13.3: Sensibilización de PWD para distintos FFT Length

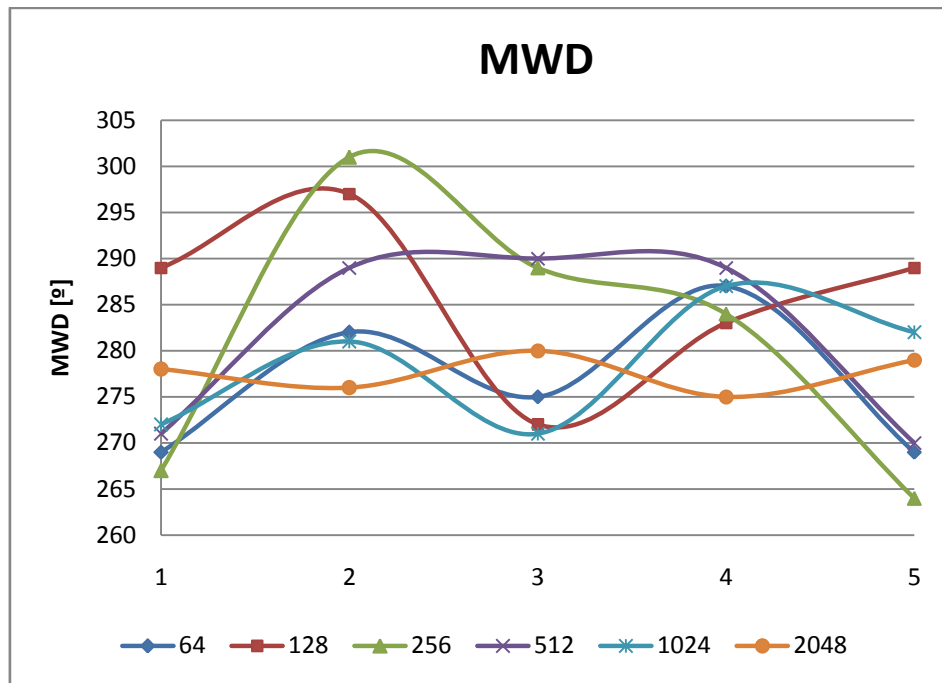


Figura 13.4: Sensibilización de MWD para distintos FFT Length

Tabla 13.1: Desviación estándar para 5 estados de mar sensibilizando FF Length

	FFT Length					
	64	128	256	512	1024	2048
Hs	0.201	0.293	0.261	0.155	0.146	0.105
Tp	2.68	3.04	2.94	3.39	2.20	3.74
PWD	7.65	8.99	15.04	10.51	6.36	2.07
MWD	7.99	9.27	15.48	10.33	6.88	2.07

Tabla 13.2: Resultados para 5 estados de mar sensibilizando FF Length

	FFT Length					
	64	128	256	512	1024	2048
Hs	0.53	0.42	0.53	0.49	0.64	0.7
	0.41	0.59	0.64	0.59	0.65	0.7
	0.76	0.82	0.63	0.81	0.69	0.67
	0.93	1.2	1.19	0.86	0.88	0.84
	0.65	0.73	0.81	0.75	0.96	0.91
Ts	10.7	10.7	8	11.1	15.1	12.5
	10.7	5.8	12.8	16	11.4	16
	10.7	12.8	12.8	12.8	16	17.4
	6.4	7.1	14.2	15.1	13.8	7.8
	5.3	6.4	8	7.5	17.1	14.6
PWD	271	291	270	272	274	279
	283	298	302	291	282	277
	277	274	290	291	273	281
	286	284	285	290	288	276
	268	290	265	271	283	280
MWD	269	289	267	271	272	278
	282	297	301	289	281	276
	275	272	289	290	271	280
	287	283	284	289	287	275
	269	289	264	270	282	279

13.2 REPRESENTACIÓN EN COORDENADAS POLARES DE ESPECTROS GENERADOS CON RNA.

Las figuras a continuación son la representación en coordenadas polares de espectros de oleaje de los gráficos de superficies presentados en el Caso 3.

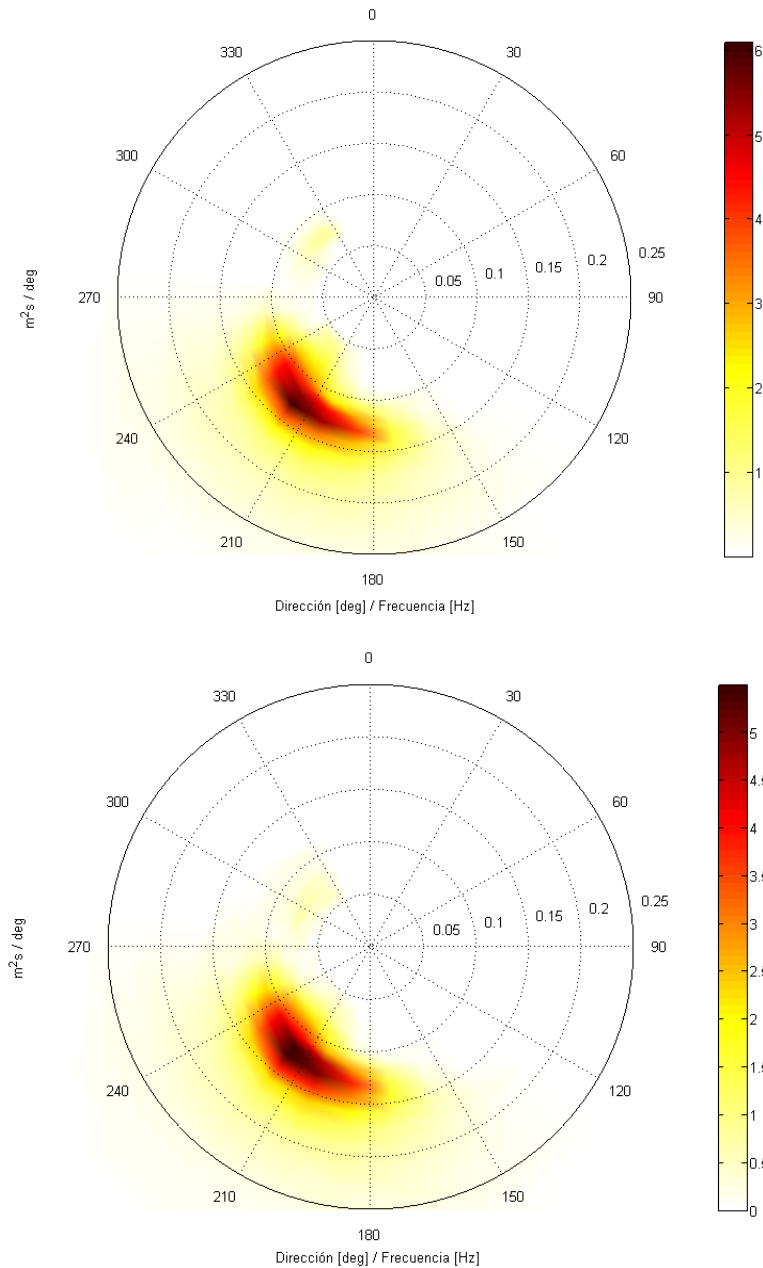


Figura 13.5: Arriba espectro medido y abajo espectro RNA para el 4-12-2006 03:00 (caso 3)

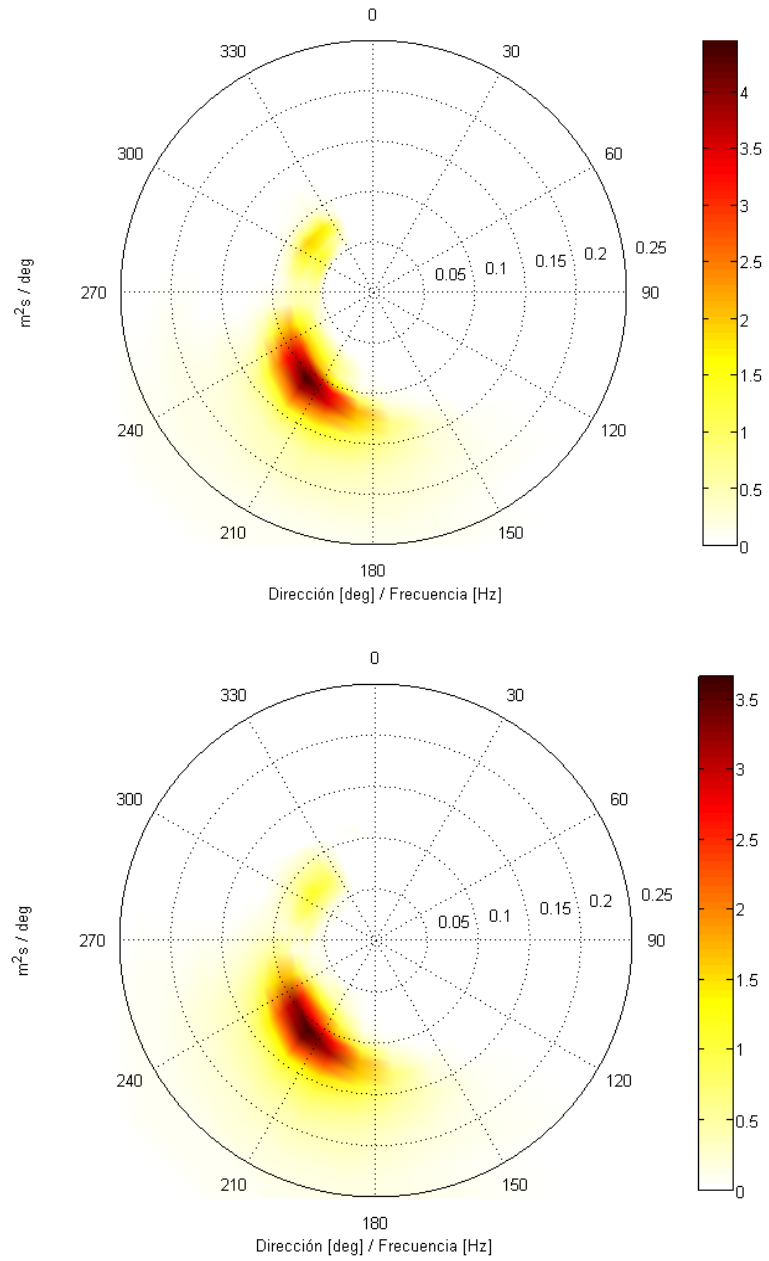


Figura 13.6: Arriba espectro medido y abajo espectro RNA para el 30-01-2006 15:00 (caso 3)

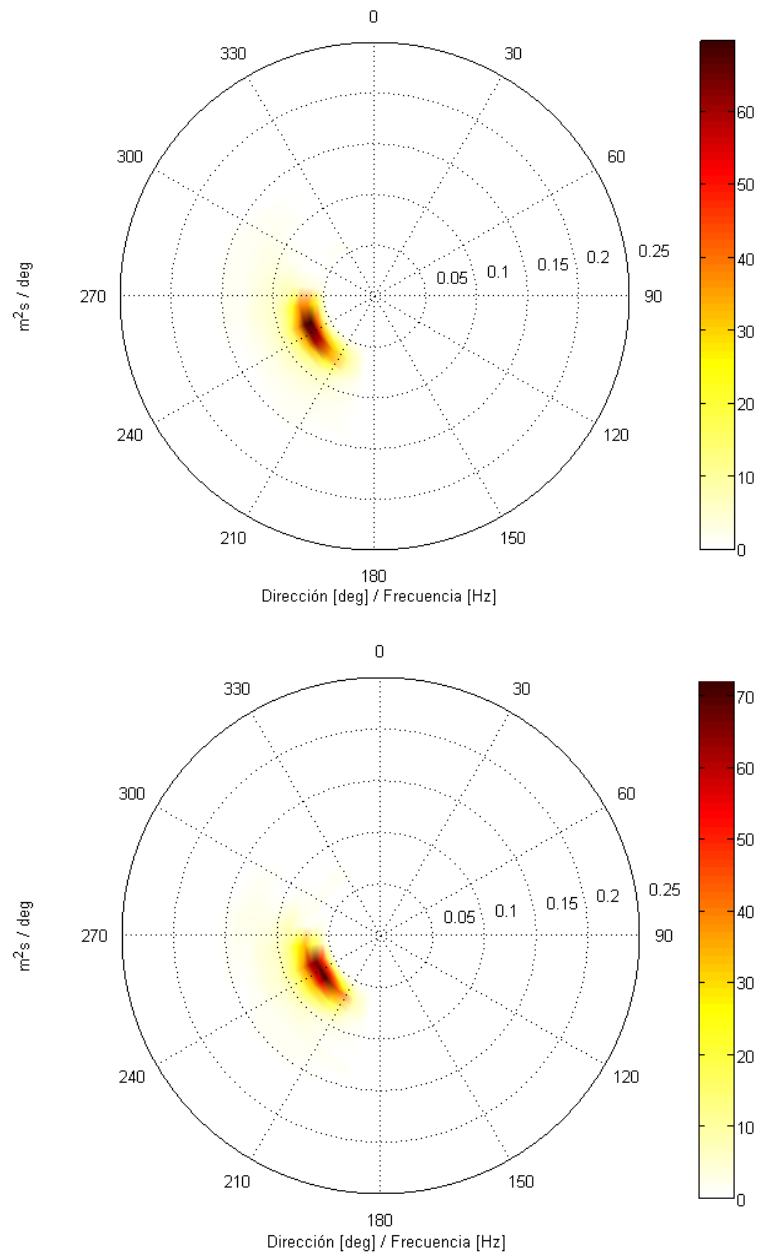


Figura 13.7: Arriba espectro medido y abajo espectro RNA para el 20-04-2006 12:00 (caso3)

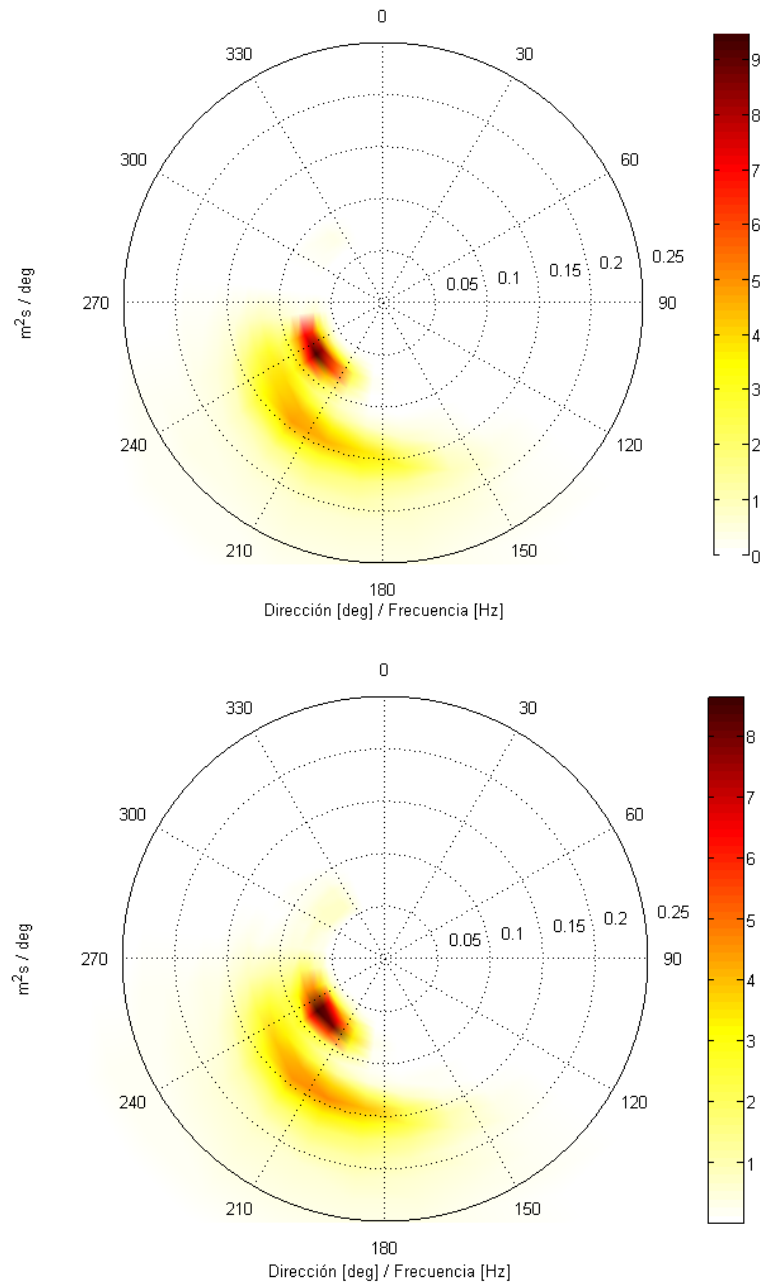


Figura 13.8: Arriba espectro medido y abajo espectro RNA para el 24-11-2006 06:00 (caso 3)

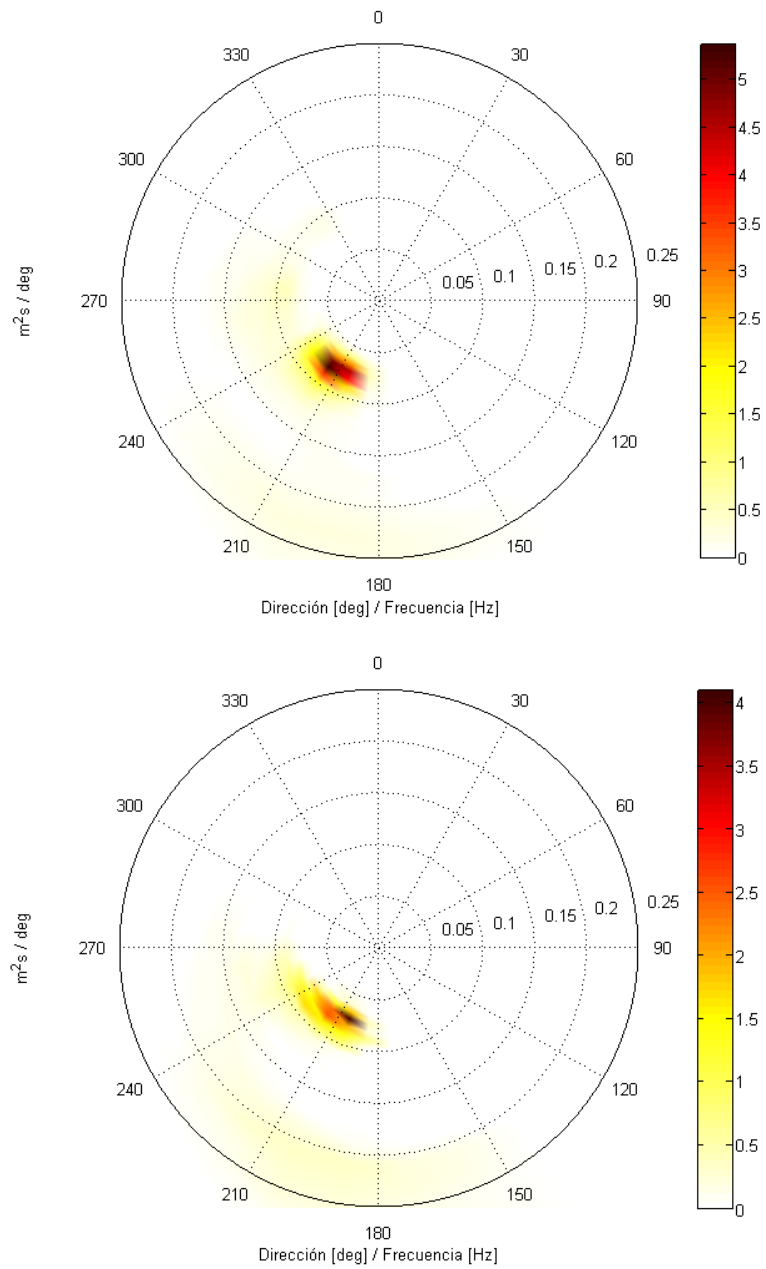


Figura 13.9: Arriba espectro medido y abajo espectro RNA para el 13-05-2006 06:00 (caso 3)

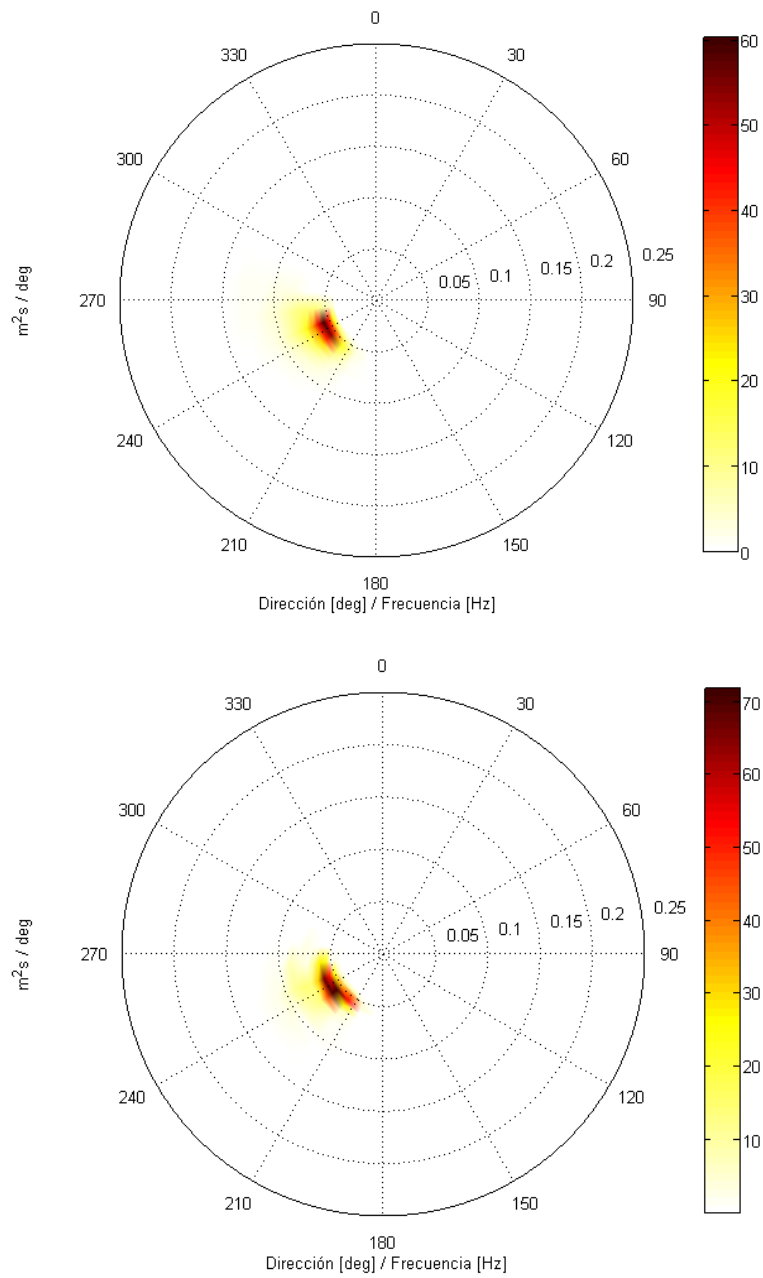


Figura 13.10: Arriba espectro medido y abajo espectro RNA para el 16-06-2006 15:00 (caso3)