

01162

UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO



UNIVERSIDAD NACIONAL
AUTÓNOMA DE
MÉXICO

FACULTAD DE INGENIERÍA

IMPLEMENTACION DE REDES NEURONALES
PARA PREDICCIÓN DE MAREAS

T E S I S

QUE PARA OBTENER EL GRADO DE
MAESTRIA EN INGENIERIA HIDRAULICA

P R E S E N T A:

JOSÉ LÓPEZ GONZÁLEZ

D I R E C T O R D E T E S I S:

Dr. PAULO SALLES A. DE ALMEIDA



MEXICO, D.F.

Agosto 2005

m346841



Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Agradecimientos

A la Universidad Nacional Autónoma de México y al Instituto de Ingeniería, por la oportunidad que me brindo de volver a sus aulas.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) que financió el proyecto 39382-U, "Red de observaciones y predicción de variables oceánicas en el Golfo de México (ROPVO-GM)

A la Dirección General de Estudios de Posgrado DGEP de la UNAM por el apoyo financiero otorgado para la realización de mis estudios

Al Servicio Meteorológico Nacional por la aportación de datos de viento y presión.

A Philippe Tissot por sus valiosos comentarios en el estudio de redes neuronales artificiales.

A mis compañeros del Instituto del grupo de Ingeniería de costas y puertos que me brindaron su apoyo

Al Dr. Paulo Salles A. de Almeida quien fue mi tutor y me ayudo en todo este tiempo

Al Dr. Rodolfo Silva Casarín por sus comentarios y sugerencias

En especial a mi familia que me apoyo incondicionalmente en este camino.

Autorizo a la Dirección General de Bibliotecas de la UNAM a difundir en formato electrónico e impreso el contenido de mi trabajo recepcional.

NOMBRE: José López González

FECHA: 10 Agosto - 2015

FIRMA: José López González

Índice

Lista de tablas y figuras	VII
Lista de variables	IX
Introducción.....	X
Objetivo	XIII
Metodología.....	XIII
Organización de la Tesis	XIII
1 Ondas oceánicas	1
1.1 Mareas.....	2
1.2 Marea viva y marea muerta	3
1.3 Fuerzas que producen la marea	5
1.4 Análisis de series de tiempo de la marea	6
1.4.1 Constituyentes armónicos	6
1.5 Marea de tormenta.....	9
2 Instrumentación estaciones mareográficas.....	11
2.1 Instrumentos de medición.....	11
2.1.1 Mareógrafo de flotador	11
2.1.2 Mareógrafo de flotador con registro de cinta perforada	13
2.1.3 Mareógrafo neumático.....	13
2.1.4 Mareógrafo acústico	14
2.2 Estaciones mareográficas en la republica mexicana	17
3 Métodos de predicción.....	19
4 Introducción a redes neuronales artificiales	27
4.1 Historia.....	27
4.2 Inspiración biológica	28
4.3 Modelos neuronales artificiales.....	30
5 Modelo de predicción con redes neuronales.....	33
5.1 Antecedentes	33
5.2 Metodología	35
5.3 Datos	35
5.4 Red Neuronal con multicapas con alimentación hacia delante (feedforward) y algoritmo de retropropagación (backpropagation)	38
5.4.1 Arquitectura Red Neuronal Multicapa	38
5.4.2 Ejemplo de algoritmo de entrenamiento	41
5.4.3 Entrenamiento red neuronal multicapa	44
5.4.4 Predicción de la marea astronómica.....	46
5.4.5 Predicción del residual.....	47
5.5 Red Neuronal ADALINE	48
5.5.1 Arquitectura	48
5.5.2 Ejemplo de algoritmo de entrenamiento	49
5.5.3 Entrenamiento	51
5.5.4 Predicción de la marea astronómica.....	52
5.5.5 Predicción del residual.....	53
5.6 Predicción de la marea real (astronómica + residual).....	55
5.6.1 Comparación entre la predicción con redes neuronales y componentes armónicos	57
5.6.2 Importancia de datos de viento y presión en la predicción de marea con RNA	61
5.7 Ejemplo práctico de predicción con redes neuronales.....	62

6 Conclusiones	66
Referencias.....	68
Anexo A código en matlab " predicción de mareas".....	71

Lista de tablas y figuras

Tabla 1-1 Clasificación de las ondas referidas al periodo	1
Tabla 1-2 NOS Constituyentes y argumentos de marea	7
Tabla 1-3 Escala de Saffir-Simpson	10
Tabla 5-1 Datos de entrada neurona multicapa	42
Tabla 5-2 Valores de error medio cuadrático entre la marea astronómica y la predicción con RNA	51
Tabla 5-3 Error medio cuadrático para diferentes combinaciones de “pesos” y días de entrenamiento	55
Figura 1-1 Clasificación de las ondas referidas al periodo-energía	2
Figura 1-2 Mareas muertas y mareas vivas de acuerdo a la posición de la luna y la tierra, con respecto a la tierra	4
Figura 1-3 Relación entre la fase de la marea teórica y la real	9
Figura 1-4 Temporada de nortes y huracanes en el Golfo de México	10
Figura 2-1 Mareógrafo simple de flotador	12
Figura 2-2 Registro de mareógrafo de flotador con cinta perforada	13
Figura 2-3 Mareógrafo neumático	14
Figura 2-4 Siguiete generación de mareógrafos	15
Figura 2-5 Localización estaciones mareográficas del CICESE	17
Figura 2-6 Localización estaciones mareográficas Secretaria de Marina	18
Figura 2-7 Localización estaciones mareográficas Instituto de Geofísica UNAM	18
Figura 3-1 Árbol de metodologías para predicción. Clasifica los posibles tipos de predicción y métodos dentro de categorías y como se relacionan con otros. Las líneas punteadas representan posibles relaciones	20
Figura 4-1 Esquema neurona biológica	29
Figura 4-2 Esquema neurona artificial	30
Figura 4-3 Representación gráfica y matricial de una red neuronal	31
Figura 4-4 Principales funciones de transferencia	31
Figura 5-1 Localización estaciones mareográficas ROPVO-GM	34
Figura 5-2 Localización estaciones mareográficas TCOON	34
Figura 5-3 Comparación entre la marea registrada (azul) y la predicción de marea astronómica con componentes armónicos (verde), residual y detalles de la comparación de la marea y la marea astronómica	36
Figura 5-4 Variación de la presión y viento	37
Figura 5-5 Arquitectura Red Neuronal con multicapas	39
Figura 5-6 Arquitectura RNA multicapa con retropropagación	42
Figura 5-7 Comparación entre diferentes combinaciones del vector de entrada (“pesos”) y la cantidad de ciclos de entrenamiento, (error en m.)	46
Figura 5-8 Predicción de marea astronómica con red neuronal multicapa	47
Figura 5-9 Predicción del residual con la red neuronal de multicapa	48
Figura 5-10 Arquitectura red neuronal ADALINE	49
Figura 5-11 Comparación de error medio cuadrático con diferentes combinaciones	52
Figura 5-12 Predicción de marea astronómica con W=4 días vector de pesos y P=12 elementos el vector de entrenamiento para 24 horas de predicción	53
Figura 5-13 Grafica de la predicción del residual (real círculos, predicción asteriscos)	54

Figura 5-14 Superficie de error para predicción con residual marea astronómica, presión y vientos.....	56
Figura 5-15 Predicción de marea real con datos de marea astronómica, residual, viento y presión	57
Figura 5-16 Comparación del error entre predicción con componentes armónicos y RNA en la zona donde existe una perturbación importante.....	58
Figura 5-17 Predicción para los días 09 al 11 de octubre ingresando componentes armónicos, residual y viento.....	59
Figura 5-18 Predicción para los días 09 al 11 de octubre ingresando solo componentes armónicos y residual	59
Figura 5-19 Comparación entre la predicción para los días del 09 al 11 considerando diferentes datos de entrenamiento.....	60
Figura 5-20 Gráfica de residual y huracanes en el año 2004.....	60
Figura 5-21 Comparación entre dos predicciones con y sin datos de viento y presión.....	61
Figura 5-22 Predicción para el 02 marzo	62
Figura 5-23 Comparación entre medición y predicción para el 02 de marzo y predicción para el 03 de marzo	63
Figura 5-24 Comparación entre la medición de marea y la predicción del día 03 de marzo y predicción para el día 04 de marzo	63
Figura 5-25 Comparación entre la medición de marea y la predicción para el día 04 de marzo y predicción para el día 05 de marzo	64
Figura 5-26 Comparación entre medición y predicción para el 05 de marzo	65
Figura 5-27 Porcentaje de error entre la marea real y la predicción con RNA para los días considerados.....	65

Lista de variables

F_g	fuerza gravitacional entre las partículas
r	distancia entre los centros de masas de los cuerpos
f	constante de gravitación universal que vale $6.67 \times 10^{-8} \text{ cm}^3/\text{gm sec}^2$.
g	es la aceleración de la gravedad (980.6 cm/seg ²) sobre la superficie de la tierra
m	masa de un cuerpo
$H(t)$	altura de la marea en cualquier instante de tiempo t
H_o	nivel medio del agua
H_n	amplitud de marea del componente n
f_n	factor de ajuste del componente n (H_n)
a_n	velocidad o periodo de una componente armónico
t	tiempo
$(V_o + u)$	valor del argumento de equilibrio para el constitutivo n en el sitio y $t=0$
θ_n	fase o época del constituyente armónico
P_m	presión manométrica
δ	densidad del agua
h	profundidad del agua sobre el dispositivo
P_a	presión atmosférica
n	valor de entrada en una neurona
a	valor de salida de una neurona
$W(t+1)$	vector de pesos en el tiempo $t+1$
$W(t)$	vector de pesos en el tiempo t
$e(t)$	error calculado en el tiempo t ; $e(t)=T-a$, donde T es el valor objetivo
$p(t)$	vector de datos en el tiempo t para una neurona
α	coeficiente de aprendizaje
M	representa el número de capas en la red
m	representa el número de la capa que va de 1 a M
$\frac{df_m}{dn}$	derivada de la función de transferencia en la capa m con respecto a n
S_m	coeficiente de sensibilidad con propagación hacia atrás

Introducción

México cuenta con una gran extensión de litoral y por ende, un enorme potencial para el desarrollo de infraestructura marítima. Dada la complejidad de la interfase mar-tierra, y dada la relativa fragilidad y vulnerabilidad de la infraestructura y actividades costeras, resulta entonces de vital importancia conocer el clima marítimo y los factores que influyen en el mismo.

Uno de los eventos que tiene gran interés en el estudio del clima marítimo, es la variación del nivel del mar, debido tanto a efectos astronómicos, fenómenos meteorológicos y fenómenos naturales, como tsunamis. El conocimiento de esta variación es de gran ayuda a la navegación, la construcción de infraestructura portuaria y demás actividades que se realizan ya sea en la costa o mar abierto.

A pesar de que la Secretaria de Marina publica tablas de predicción de mareas para los principales puertos del país, éstas no toman en cuenta las variaciones por fenómenos meteorológicos o de otra naturaleza, existiendo en varias zonas de nuestro litoral, una apreciable diferencia entre las tablas y la marea registrada.

En algunas zonas del país, en particular donde la amplitud de la marea astronómica no es muy elevada, existe una apreciable diferencia entre la marea astronómica, que se predice utilizando solamente los componentes armónicos y la marea real que se presenta en el sitio. La diferencia radica principalmente en que solo se hace la predicción de marea periódica generada por fuerzas gravitatorias y no se toma en cuenta la marea generada por otro tipo de fuerzas, lo que puede resultar en situaciones de riesgo para embarcaciones cuando los niveles de la marea son menores a los esperados, para la población cuando los niveles de la misma pueden causar inundaciones y en otros casos en la toma incorrecta de decisiones cuando se necesita proyectar y diseñar obras portuarias o de infraestructura cerca de la playa.

Hasta hace poco tiempo la predicción de marea no astronómica solo podía hacerse con modelos numéricos. Actualmente las redes neuronales han venido ganando terreno en el campo de la investigación y la implementación. En este sentido las redes neuronales artificiales se han venido utilizando en ciertos casos de predicción dando muy buenos resultados, el único requisito para el buen desempeño de las mismas es contar con datos históricos confiables para el entrenamiento de la RNA.

La diferencia en precisión entre un modelo y otro para la predicción de marea no astronómica no es significativa, sin embargo el tiempo de cómputo si lo es. Mientras que la simulación numérica de un modelo matemático puede tomar horas (Bautista et al 2003), la red neuronal solo requiere de unos cuantos minutos. El inconveniente de utilizar redes neuronales, es que forzosamente se requiere instrumentar los sitios de interés y recabar datos históricos para entrenar la red, lo que no necesariamente requiere un modelo numérico. Sin embargo para que un modelo numérico trabaje satisfactoriamente es necesario de una buena caracterización de la zona de interés, lo que desafortunadamente en muchas ocasiones tampoco se tiene.

Ya que tanto una como otra técnica de predicción, tiene ventajas y desventajas, los parámetros de decisión dependerán de las características del sitio y los datos con los que se cuenta.

Por ejemplo si no se tienen registros del sitio de interés la única solución será la utilización del modelo numérico, aunque no se tenga una buena caracterización del área, por el contrario si se tienen registros del sitio, la solución pueden ser las RNA.

Un punto de equilibrio entre estos dos métodos es la utilización combinada de los métodos de predicción cuando no se tienen registros de la zona, en este caso el modelo numérico puede servir para entrenar la RNA.

Por otro lado, no obstante que México cuenta con varias estaciones mareográficas en su litoral (en promedio un mareógrafo para cada 300-400 km de costa), la disponibilidad de los datos no es óptima, y la ubicación de los equipos no siempre hace que los datos sean representativos de zonas extensas.

Con el fin de proporcionar mediciones de los niveles de marea en tiempo real, evaluar posibles perturbaciones asociadas a inestabilidades océano-meteorológicas e implementar un sistema de alerta oportuna sobre los posibles efectos por la presencia de frentes fríos y ciclones tropicales en el Golfo de México, surgió un proyecto, patrocinado por CONACYT, denominado "Red de observaciones y predicción de variables oceánicas en el Golfo de México (ROPVO-GM). Este proyecto consiste en un sistema para la medición de las variables meteorológicas y del nivel del mar a lo largo de la costa de los estados de Tamaulipas y Veracruz. Esta red está asociada a la Red de Observaciones Oceánicas de la Costa de Texas (TCOON por sus siglas en inglés Texas Coastal Ocean Observation Network), que de contar con 3 estaciones en 1989 ahora cuenta con un total de 42, conectadas a una red que proporciona mediciones de los niveles de marea en tiempo real, mismas que se pueden consultar en el Word Wide Web.

Uno de los objetivos del proyecto y que es tema de este trabajo es desarrollar un modelo de predicción a corto plazo de los niveles de marea, incorporando los datos medidos por los Sistemas Meteorológicos, tanto de México como de Estados Unidos.

En la actualidad ya se encuentran operando las estaciones del Mezquital y Tampico en Tamaulipas, las cuales se pueden consultar en el Word Wide Web en las siguientes direcciones: <http://lighthouse.tamucc.edu/qc/128> y <http://lighthouse.tamucc.edu/qc/129> para Tampico y el Mezquital, respectivamente además de todas las estaciones del TCOON.

Objetivo

Implementar un modelo de predicción de marea que permita estimar anticipadamente (de 12 a 24 h) tanto la marea astronómica, meteorológica o la combinación de estas, con el uso de Redes Neuronales Artificiales (RNA).

Metodología

Se obtuvieron los datos de las elevaciones del nivel del mar de la estación mareográfica de Tampico en Tamaulipas, los cuales fueron analizados y procesados para corregir anomalías en la captura de los mismos.

Posteriormente, se hizo el análisis armónico y se compararon los resultados con la marea real del sitio observando en la temporada de ciclones tropicales y frentes fríos, (comúnmente conocidos como “nortes”), una fuerte diferencia entre las mareas real y astronómica.

Una vez detectada la importancia de una buena estimación de marea real se investigaron los métodos de predicción y se seleccionó como el más adecuado el modelo de redes neuronales

Con los datos recabados se llevo a cabo la validación del modelo de RNA, obteniendo uno capaz de estimar con un buen grado de exactitud la predicción de la marea real para por lo menos 12 horas de anticipación.

Organización de la Tesis

El presente trabajo consta de cinco capítulos:

Capítulo 1 Ondas oceánicas

Se estudian los componentes básicos, las fuerzas y los tipos de marea así como la manera de restituir una marea astronómica con datos del sitio y las leyes que rigen su comportamiento.

Capítulo 2 Instrumentación estaciones mareográficas

Se describen los mareógrafos más utilizados en la actualidad, su funcionamiento, la forma de capturar los niveles de agua y una distribución de los mismos en la Republica Mexicana.

Capítulo 3 Métodos de predicción

En este capítulo se presentan los principales métodos de predicción que existen, dando las características y tipos de datos que pueden manejar, así como una comparación de estos con los modelos de redes neuronales. Se expresa la razón de la utilización de modelos con redes neuronales en la tarea de estimar las elevaciones de la superficie del mar.

Capítulo 4 Introducción a redes neuronales artificiales.

Se da una breve introducción de la historia de las redes neuronales, su surgimiento, los principales creadores y el porque son llamadas de esta manera, atendiendo a la semejanza con una neurona humana. También se da una descripción de los principales componentes de estos modelos y de su funcionamiento, sus características y su representación matemática.

Capítulo 5 Modelo de predicción con redes neuronales.

Este capítulo integra en cierta manera los capítulos anteriores en la aplicación práctica del conocimiento sobre mareas, la forma de medir los niveles del agua y las técnicas de predicción, encontrando un modelo de red neuronal capaz de estimar adecuadamente las elevaciones del nivel del mar para 12 horas posteriores al último registro.

Cabe mencionar que el proyecto contempla la disposición de los registros de elevaciones del mar muy cercanos a tiempo real directamente del Internet, lo que traería consigo que las estimaciones del nivel del mar puedan ser corregidas cada vez que se tengan nuevos registros en la base de datos.

1 Ondas oceánicas

Para entender los fenómenos que ocurren en la naturaleza, se han desarrollado en sin fin de teorías, que son un intento de explicar mediante modelos matemáticos tales fenómenos. Uno de estos fenómenos son las ondas oceánicas las cuales son generadas principalmente por la acción del viento al soplar sobre la superficie del mar, pero también pueden ser provocados por terremotos, desprendimientos de grandes masas de tierra y la atracción gravitatoria.

Las ondas oceánicas se pueden clasificar de acuerdo a la fuerza generadora o a su periodo. En la Tabla 1-1 Clasificación de las ondas referidas al periodo Tabla 1-1 se muestra una clasificación de las ondas de acuerdo a su periodo. Por otra parte, en la Figura 1-1 se muestra un esquema en el que además del periodo, las ondas se clasifican en función de la energía que transportan, así como de la fuerza que las generan y la fuerza restauradora o de equilibrio. Este trabajo centra la atención en las ondas de largo periodo (5 min-24 h) principalmente mareas astronómicas y de tormenta o meteorológicas.

Tabla 1-1 Clasificación de las ondas referidas al periodo

Nombre	Período T	Longitud L	Altura H	Fuerza generadora	Fuerza restauradora
Capilares	0 – 0.1 s	2 – 7 cm	1 – 2 mm	viento	tensión superficial
Ultragravedad	0.1 s – 1 s	centímetros	centímetros	viento	tensión superficial y gravedad
Gravedad	1 s – 30 s	metros a cientos de metros	centímetros – 15 m	viento	Gravedad
Infragravedad	30 s – 30 min	100 – 200 m	pequeña	viento	gravedad, Coriolis
Largo período	5 min – 24 hr	Pueden llegar a ser de escala planetaria	1 – 5 m	sismo, derrumbes, atracción de cuerpos celestes	gravedad, Coriolis
Transmarea	más de 24 hr	-	0 – 12 m	Oscilaciones climáticas	gravedad, Coriolis

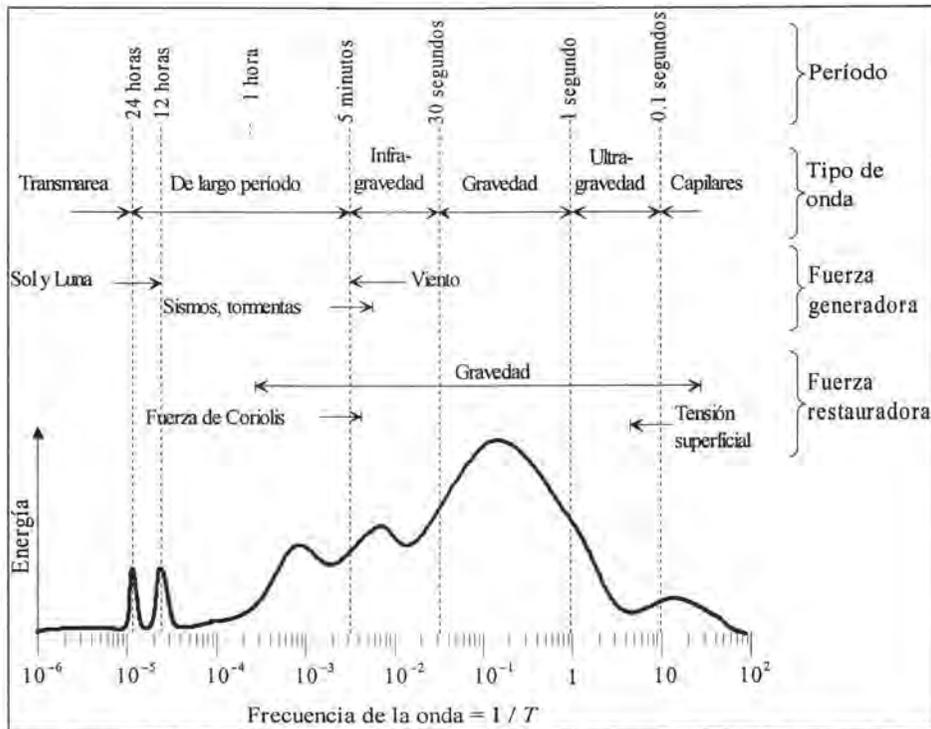


Figura 1-1 Clasificación de las ondas referidas al periodo-energía

1.1 Mareas

Una base importante para el análisis científico de nivel del mar consiste en una larga serie de medidas del mismo. Cualquier medida instantánea de nivel del mar en una serie puede ser considerada como la suma de tres componentes:

$$\text{Nivel observado} = \text{nivel medio del mar} + \text{marea astronómica} + \text{residuos}$$

Cada una de estas partes son controladas por procesos físicos separados y las variaciones de cada parte son esencialmente independientes de las variaciones en las otras partes. Hay muchas maneras de definir los componentes. Un conjunto de definición aceptable para describir estos componentes son:

Las mareas son movimientos de ascenso y descenso del nivel del mar que tienen una amplitud y una fase relacionada con alguna fuerza generadora y se traducen en ondas largas propagándose en los diversos océanos y mares.

El nivel medio del mar es el promedio del nivel del mar, normalmente basado en valores a cada hora tomados en un lapso de por lo menos un año. Para los propósitos de la Geodesia el nivel medio puede definirse a partir de los datos de varios años.

Las mareas astronómicas son notables ascensos y descensos periódicos de grandes cuerpos de agua de la tierra. Las mareas se producen como resultado de la atracción

gravitatoria de los cuerpos celestes principalmente la luna y el sol, y en menor medida los demás cuerpos celestes. Debido a su cercanía a la tierra, la luna induce el efecto más fuerte en las mareas.

Como consecuencia de la diferencia en la elevación de la superficie del agua, se producen corrientes de marea

Los residuos son los componentes de la marea que permanecen después de quitar la marea astronómica. Estos son irregulares, como es la variación en el clima.

La altura o rango de la marea, es la distancia vertical entre la elevación máxima de la superficie del agua y la elevación mínima consecutiva, y es función de la posición relativa de la luna y el sol con respecto a la tierra, y varía de una posición a otra.

Típicamente, el ciclo de la marea dominante se relaciona con el paso de la luna encima de un meridiano fijo. Esto ocurre en promedio 50 min después cada día subsiguiente. Este paso de la luna produce aproximadamente dos mareas por día (marea semidiurna), con un máximo de marea aproximadamente cada 12 hr y 25 min. Sin embargo, diferencias en la posición relativa de la luna y el sol en conjunción con condiciones locales puede producir mareas que exhiben sólo un ciclo de marea por día (marea diurna).

Las mareas mixtas exhiben características de mareas semidiurnas y diurnas. En ciertos tiempos del mes lunar, se producen dos crestas por día, mientras que en otros momentos la marea es diurna. Cuando la amplitud es máxima en un mes lunar se la llama marea viva y cuando la marea es mínima, marea muerta.

1.2 Marea viva y marea muerta

Los valles y las crestas de la marea semidiurna pueden describirse con una forma casi sinusoidal y se alcanza un valor máximo de la cresta cada 12 h y 25 min a este máximo generalmente se le llama pleamar e igualmente se alcanza un valor mínimo conocido como bajamar. Este periodo representa la mitad del día lunar. Se experimentan la generación de dos mareas en el día lunar porque las mareas representan la respuesta a la atracción gravitatoria, principalmente, de la luna en un lado de la tierra, equilibrada por una fuerza centrífuga en el lado opuesto de la tierra. Estas fuerzas crean una protuberancia o desviación exterior en la superficie del agua en dos lados contrarios de la tierra.

La magnitud de desviación de la marea parcialmente es una función de la distancia entre la luna y la tierra. Cuando la luna está en perigeo; es decir, más cerca a la tierra, el rango de la marea es mayor que cuando esta más alejada, en apogeo.

La desviación de la superficie del agua para marea semidiurna cambia de acuerdo a la posición relativa del sol y la luna. Las amplitudes que conectan dos pleamares sucesivas se van incrementando gradualmente desde una altura mínima a un valor máximo, y entonces

vuelven a disminuir hasta un valor mínimo. La marea en periodos de amplitud máxima son llamadas mareas vivas, y las mareas en tiempos de amplitud mínima son llamadas mareas muertas. Este ciclo de marea viva a muerta ocurre dos veces en un periodo de aproximadamente 29 días.

Las mareas vivas ocurren cuando el sol y luna están alineados, esto ocurre cuando hay luna nueva y el sol y la luna están en el mismo lado de la tierra, o en luna llena, cuando la luna y el sol están en lados opuestos de la tierra. Las mareas muertas ocurren en los puntos intermedios, que son los primero y terceros cuartos de la luna. La **Figura 1-2** es una representación esquemática de las fases predominantes de la marea.

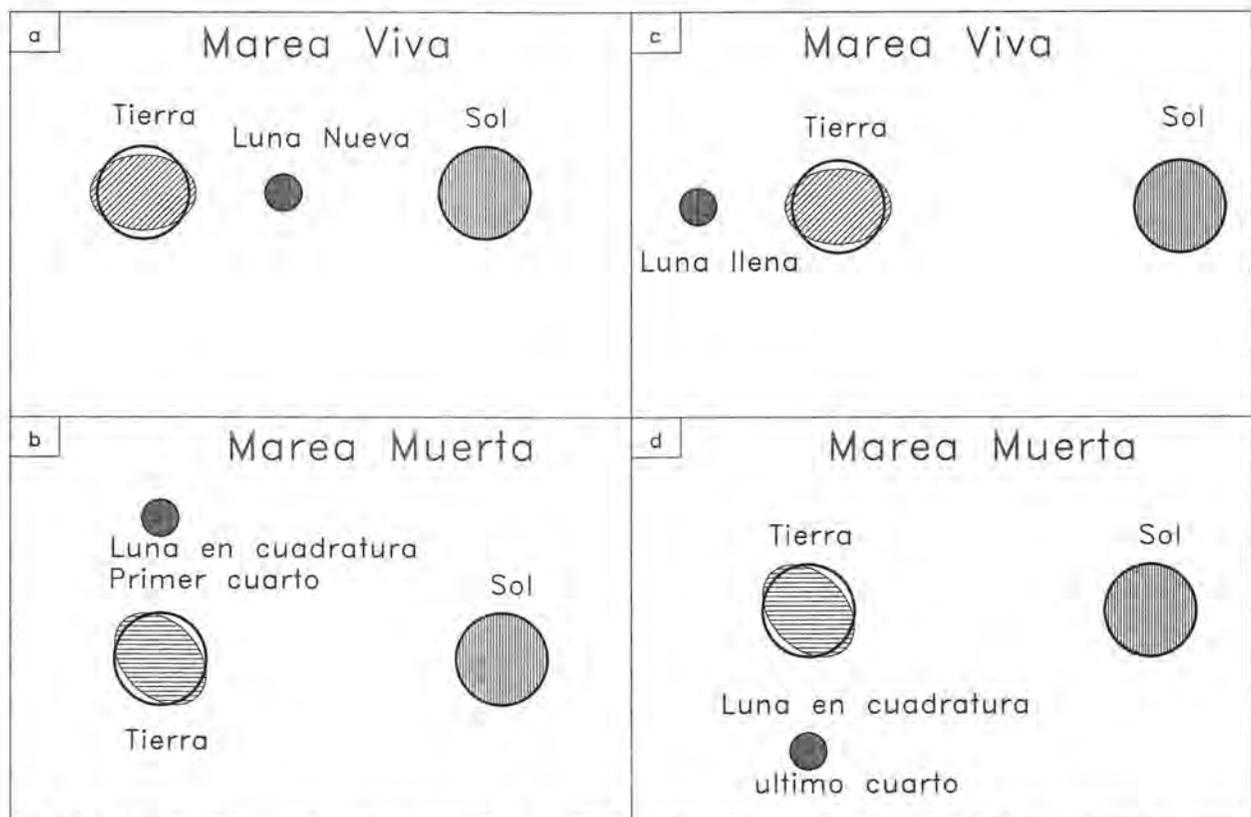


Figura 1-2 Mareas muertas y mareas vivas de acuerdo a la posición de la luna y la tierra, con respecto a la tierra

1.3 Fuerzas que producen la marea

La ley de gravitación universal fue publicada por Newton en 1686. La ley de gravitación universal de Newton, dice que cada partícula de materia en el universo atrae a otra partícula con una fuerza que es directamente proporcional al producto de las masas de las partículas e inversamente proporcional al cuadrado de la distancia entre ellos. Los aspectos cuantitativos de la ley de atracción gravitatoria entre dos cuerpos de masa m_1 y m_2 pueden escribirse como sigue:

$$F_g = f \frac{(m_1 m_2)}{r^2} \quad (1)$$

donde

- F_g fuerza gravitacional entre las partículas
- r distancia entre los centros de masas de los cuerpos
- f constante universal que vale $6.67 \times 10^{-8} \text{ cm}^3/\text{gm sec}^2$.

La fuerza de gravitación de la tierra con masa m_2 sobre una partícula con masa m_1 puede ser obtenida de la ecuación (1). Si la fuerza de gravedad esta dada por:

$$F_g = m_1 g \quad (2)$$

donde

- g aceleración de la gravedad (980.6 cm/seg²) sobre la superficie de la tierra
- m_1 masa de la tierra.

Sustituyendo los valores en la ecuación (1) se tiene una expresión para la constante gravitacional que puede ser escrita como:

$$f = \frac{g r^2}{m_2} \quad (3)$$

1.4 Análisis de series de tiempo de la marea

El análisis armónico de mareas esta basado en la suposición de que el ascenso y descenso de la marea en cualquier localidad, puede ser expresado matemáticamente por la suma de una serie de términos armónicos teniendo cierta relación con consideraciones astronómicas. Una función armónica simple es una cantidad que varia con el coseno de un ángulo que crece uniformemente con el tiempo.

1.4.1 Constituyentes armónicas

De acuerdo a la teoría del equilibrio de fuerzas, la marea teórica puede predecirse en un punto fijo del mar como una suma de varios términos armónicos contenidos en la representación de la expansión de funciones consenoidales. Sin embargo, la marea real no se ajusta a este valor teórico debido a la fricción e inercia, así como a las diferencias en la profundidad y distribución de masas en la tierra.

Debido a los aspectos anteriores, es imposible predecir la marea exactamente en cualquier lugar de la tierra basándose únicamente en la teoría. Sin embargo, las fuerzas productoras de marea (y sus términos de componentes de expansión) son armónicos; es decir, pueden ser expresados como una función de cosenos cuyo argumento aumenta linealmente con el tiempo de acuerdo a un periodo conocido, y si se combinan los términos de expansión de las fuerzas marea-productoras con los términos de distinto periodo, entonces la marea puede representarse como una suma de un número relativamente pequeño de elementos armónicos. Cada componente de un periodo está dado en la forma del producto de un coeficiente de amplitud y el coseno de un argumento de periodo conocido, con ajustes de la fase basados en el tiempo y lugar de medición.

Los datos observados en un momento y lugar específico se usan para determinar los coeficientes y argumentos de cada componente armónico, la suma de estos componentes armónicos se usan para construir la marea en cualquier instante de tiempo. Este concepto representa la base del análisis armónico, es decir; usar datos observados para desarrollar coeficientes específicos del sitio que pueden emplearse para reconstruir una serie de tiempo de marea como una suma lineal de términos individuales de periodo conocido.

La altura de la marea para cualquier lugar y tiempo puede ser escrita como una función de componentes armónicos de acuerdo a la ecuación general siguiente.

$$H(t) = H_o + \sum_{n=1}^N f_n H_n \cos(a_n t + (V_o + u) - \theta_n) \quad (4)$$

donde

$H(t)$	elevación de la marea en cualquier instante de tiempo t
H_o	nivel medio del agua
H_n	amplitud de marea del componente n
f_n	factor de ajuste de la amplitud del componente n (H_n)

a_n	frecuencia angular del componente $n = \frac{2\pi n}{T}$
t	tiempo
$(V_0 + u)$	valor del argumento de equilibrio para el componente en el sitio y $t=0$
θ_n	fase del componente n

En la fórmula anterior, la marea se representa como la suma de un coeficiente multiplicado por el coseno de su argumento respectivo. Un número finito de componentes se usan en la reconstrucción de una señal de marea. Los valores para los argumentos de sitios específicos (H_0 , H_n , y θ_n) son calculados de los datos de series de tiempo de la marea observada, normalmente, de un análisis de mínimos cuadrados. The National Oceanic and Atmospheric Administration's (NOAA) y el Nacional Ocean Survey (NOS), generalmente en sus publicaciones utiliza 37 componentes en sus análisis armónicos (principalmente basados, en el análisis de un año mínimo de datos del sitio). Los componentes utilizados por NOS, junto con el periodo correspondiente y velocidad correspondiente de cada uno, se lista en Tabla 1-2. Los argumentos del tiempo específicos (f_n y $V_0 + u$) son determinados de fórmulas o tablas

La mayoría de los componentes listados en la Tabla 1-2 esta asociado con un subíndice que indica el número aproximado de ciclos por el día solar (24 hr). Los constituyentes con subíndices de 2 están relacionados con la marea semidiurna y producen una contribución de la marea de aproximadamente dos pleamares por día. Los constituyentes diurnos contribuyen una vez al día y tienen un subíndice de 1. Los Símbolos sin subíndice son constituyentes de largo periodo y tienen periodos mayores que un día; por ejemplo, el constituyente Anual Solar **Sa** tiene un periodo de aproximadamente 1 año.

Tabla 1-2 NOS Constituyentes y argumentos de marea

Simbolo	Vel grados/hr	Periodo hrs	Simbolo	Vel grados/hr	Periodo hrs
M2	28.984	12.421	Mm	0.544	661.765
S2	30.000	12.000	Ssa	0.082	4390.244
N2	28.439	12.659	Sa	0.041	8780.488
K1	15.041	23.935	Msf	1.015	354.680
M4	57.968	6.210	Mf	1.098	327.869
O1	13.943	25.819	p1	13.471	26.724
M6	86.952	4.140	Q1	13.398	26.870
(MK)3	44.025	8.177	T2	29.958	12.017
S4	60.000	6.000	R2	30.041	11.984
(MN)4	57.423	6.269	(2Q)1	12.854	28.007
v2	28.512	12.626	P1	14.958	24.067
S6	90.000	4.000	(2SM)2	31.015	11.607
μ 2	27.968	12.872	M3	43.476	8.280
(2N)2	27.895	12.906	L2	29.528	12.192
(OO)1	16.139	22.306	(2MK)3	42.927	8.386
λ 2	29.455	12.222	K2	30.082	11.967
S1	15.000	24.000	M8	115.936	3.105
M1	14.496	24.834	(MS)4	58.984	6.103
J1	15.585	23.099			

En la mayoría de los análisis armónicos de datos de marea en el norte del continente Americano, la mayoría de los componentes mostrados anteriormente tienen contribuciones de amplitud que son despreciables con respecto a la magnitud de la marea completa. Por ejemplo, en el Golfo de México y costa del este de los Estados Unidos, más del 90% de la energía de la marea puede ser representada por las amplitudes de los componentes semidiurnos M_2 , S_2 , N_2 , y K_2 y por los componentes diurnos K_1 , O_1 , P_1 , y Q_1 . En otros sitios, se necesitan muchos más componentes de la marea para representar adecuadamente la marea total.

Dos categorías de componentes son necesarias para reconstruir una señal de marea:

1. Aquéllos que representan la elevación de la superficie de agua.
2. Aquéllos que especifican un tiempo y la fase asociada con ese tiempo.

Por ejemplo, el valor para H_n en la ecuación (4) es la amplitud del componente n y es una función del sitio y las variaciones de la marea debidas al efecto nodal de la luna (cambios en la latitud). El efecto nodal de la luna es tomado en cuenta con la introducción del factor de nodo f_n que modifica cada amplitud constitutiva para que corresponda a un periodo de tiempo específico. Normalmente se especifican valores de medio año para la serie de tiempo reconstruida porque los factores de nodo varían lentamente con el tiempo. Las ecuaciones para calcular los factores f_n de nodo son dadas por Schureman (1924).

La segunda categoría de argumentos especifica la fase de la altura del agua para cada constituyente con respecto al tiempo y el lugar. Estos argumentos están basados en el hecho de que las fases de los constituyentes de la marea observada no coinciden con las fases de los constituyentes correspondientes de la marea teórica. Por ejemplo, una pleamar no ocurre directamente bajo la luna. Hay un retraso entre la posición de la fuerza marea-productora (es decir, posición de la luna) y el tiempo en el que se observa la marea alta. Este retraso, es debido a fuerzas de fricción e inercia que actúan en la propagación de la marea, y es llamado la fase del constituyente θ_n en la ecuación (4).

El valor de θ_n es aproximadamente constante en cada lugar del mundo porque representa el retraso real entre la contribución del paso de la fuerza marea-productora (por ejemplo la luna) en un sitio específico y la marea real en ese punto.

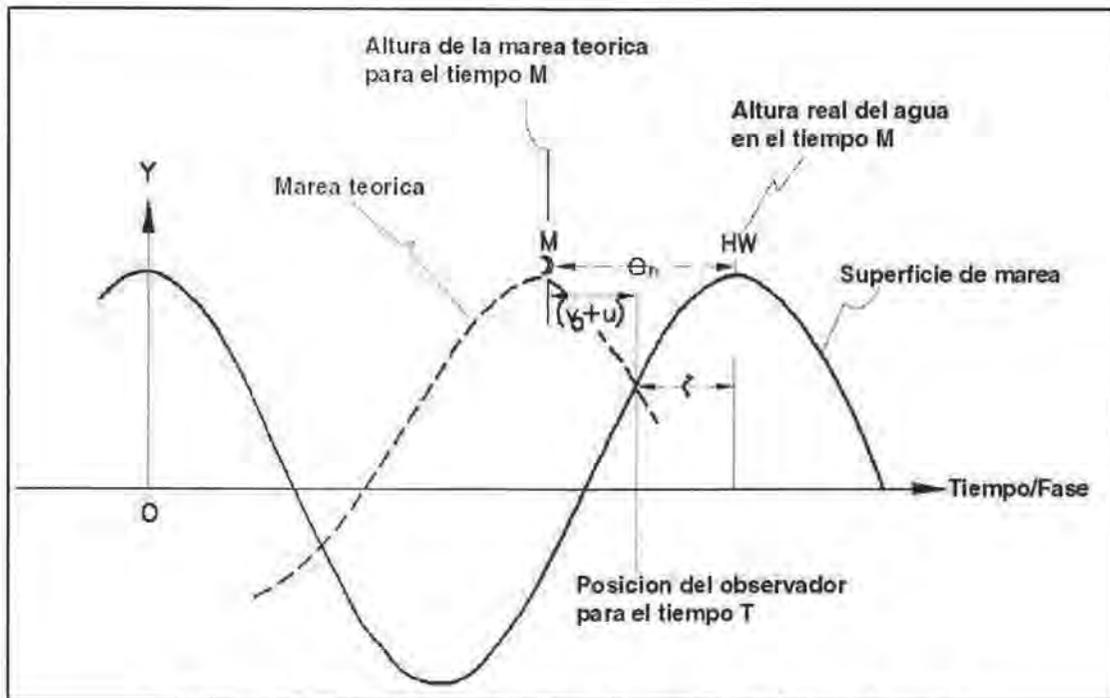


Figura 1-3 Relación entre la fase de la marea teórica y la real

1.5 Marea de tormenta

Una marea de tormenta se define como una sobrelevación en el nivel medio del mar debido a factores meteorológicos resultado de las fuerzas del viento sobre el agua, cambios de presión atmosférica, movimiento de sistemas de tormenta y configuración del fondo marino. En el área de estudio la altura de la marea de tormenta es obtenida por la substracción de la predicción de marea astronómica al registro de marea del sitio, aunque en algunas ocasiones esta diferencia no corresponde únicamente a la marea meteorológica, si no también puede representar la sobrelevación provocada por tsunamis por ejemplo.

Durante la ocurrencia de ciclones se presenta esta sobrelevación. Las mareas de tormenta igual que las mareas astronómicas, están asociadas a una sobrelevación o a un decremento del nivel medio del mar, pero a diferencia de las primeras su fuerza de generación no es la gravedad, sino la disminución de la presión atmosférica y el viento, entre otros.

El NHC (National Hurricane Center) maneja que la reducción en la presión atmosférica en un milibar es equivalente a un incremento de 1 cm en el nivel del agua, esto para aguas profundas, sin embargo como se mencionó, la sobrelevación depende de varios factores, entre ellos la configuración del fondo marino. La Tabla 1-3 muestra la elevación estimada del nivel de la superficie del mar para las diferentes categorías de huracán, donde se puede observar que, de presentarse un huracán con categoría 5 la sobrelevación podría ser igual o mayor a 5.5 m lo que se traduce en riesgo potencial para la población costera.

Y en la figura Figura 1-4 se muestra la temporada de nortes (vientos del norte y noreste causados por masas de aire frío provenientes de los EEUU y Canadá con ráfagas de hasta 75 km/h y a menudo acompañados por lluvias) y huracanes en el Golfo de México, donde se puede observar que la mayor parte del tiempo el Golfo de México tiene perturbaciones atmosféricas, por consiguiente la sobrelevación por tormenta puede significar un parámetro importante en esta zona del país.

Tabla 1-3 Escala de Saffir-Simpson

Categoría	Presión central (mb)		Vientos (km/h)		Elevación de la marea (m)	Características
Perturbación Tropical	1008.1	1010				Ligera circulación de vientos
Depresión Tropical	1004.1	1008	<62			Localmente destructivos
Tormenta Tropical	985.1	1004	62.1	118	1.1	Presenta efectos destructivos
Huracán categoría 1	980.1	985	118.1	154	1.5	Altamente destructivos
Huracán categoría 2	965.1	980	154.1	178	2.0-2.5	Altamente destructivos
Huracán categoría 3	945.1	965	178.1	210	2.5-4.0	Extremadamente destructivos
Huracán categoría 4	920.1	945	210.1	250	4.0-5.5	Extremadamente destructivos
Huracán categoría 5	<920		250.1	>250	>5.5	El más destructivo

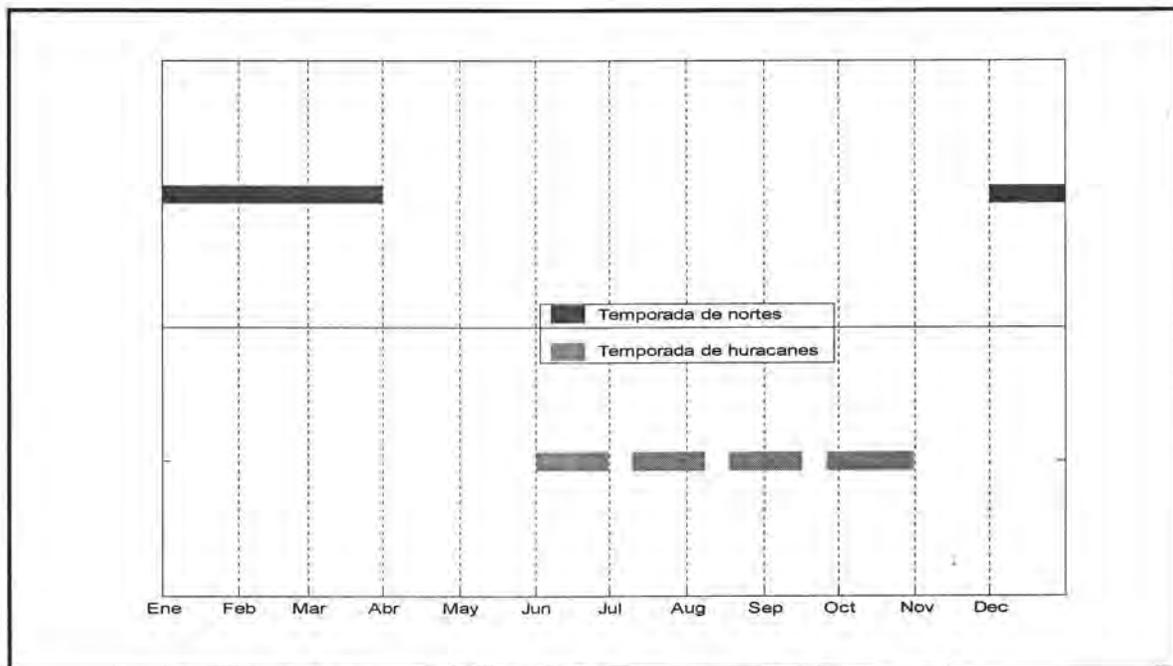


Figura 1-4 Temporada de nortes y huracanes en el Golfo de México

2 Instrumentación estaciones mareográficas

La medida del nivel del mar tiene una larga historia. En la antigüedad en muchos sitios se pudo ligar los movimientos regulares del mar a los movimientos del sol y de la luna. Otros consideraban que las mareas eran debidas a poderes de los Dioses.

En el siglo 19 los estudios estaban relacionados con movimientos verticales de la tierra en la creencia de que el nivel medio del mar era constante sobre largos periodos de tiempo y los cambios del nivel medio del mar reflejaban estos movimientos. Se aprecia ahora generalmente que ni la tierra ni el nivel medio del mar son permanentes y que los movimientos verticales de la tierra están asociados con cambios glaciales y otros procesos tectónicos. Los cambios en el nivel medio del mar están relacionados con modificaciones en el volumen de agua, procesos tectónicos y a las variaciones en las corrientes del océano.

Propuestas recientes para coordinar estudios del cambio del clima mundial han identificado el nivel medio del mar como indicador indirecto en diversos procesos como son por ejemplo, la fusión glacial, aumento en el volumen del agua del mar debido a calentamiento global, cambio en la intensidad y dirección de las corrientes entre otros y todas las consecuencias que esto ocasiona.

Los estudios globales requieren de una red global bien distribuida y apropiada colaboración internacional definiendo normas para tomar buenas observaciones, generar bases de datos, y publicaciones de las mismas.

México a pesar de contar con una gran extensión de litoral no dispone de una adecuada instrumentación para obtener los parámetros oceanográficos necesarios para caracterizar el clima marítimo, lo que imposibilita el correcto estudio de algunos fenómenos oceanográficos. Para solucionar en parte este problema, es necesario contar con estaciones mareográficas adecuadas que tengan la capacidad de almacenar datos recolectados de buena calidad y que puedan ser enviados automáticamente a un centro de acopio para poderlos distribuir eficaz y oportunamente.

2.1 Instrumentos de medición

Existen diversos procedimientos y diferentes equipos para medir la marea, los cuales pueden variar dependiendo del uso y calidad de la medición. En esta sección se darán a conocer brevemente algunos de los instrumentos existentes y las técnicas de medición utilizadas.

2.1.1 Mareógrafo de flotador

En su forma más simple un mareógrafo de flotador puede ser como el mostrado en la Figura 2-1 El flotador colocado en la superficie del agua es conectado con un cable que pasa por encima de una polea a un peso. Como el flotador sube en agua creciente el peso desciende la misma cantidad y el cable que pasa encima de la polea causa que la polea ruede. El

ángulo de rotación es directamente proporcional al cambio del nivel de agua. La segunda polea esta unida al mismo eje de rotación por lo tanto esta rodara la misma cantidad que la primera, pero como su diámetro es más pequeño la pluma atada al cordón que pasa encima de esta polea se moverá una distancia más pequeña que el flotador aunque exactamente de la misma manera. La pluma puede escribir en un papel y dibujar el movimiento del flotador que en este caso representa la superficie de agua aunque en una escala más reducida. La escala entre el movimiento de la pluma y el agua estará determinada por los diámetros seleccionados de las dos poleas.

Si el papel se hace pasar normal al camino de la pluma a una velocidad fija se dibujará una curva representando el registro continuo de la altura de agua contra el tiempo. El flotador debe operar dentro de un mar en calma para que tenga un funcionamiento satisfactorio. La entrada cónica forma un cercamiento para impedir la entrada de cambios de nivel brusco debidos a la presencia de oleaje de periodo corto.

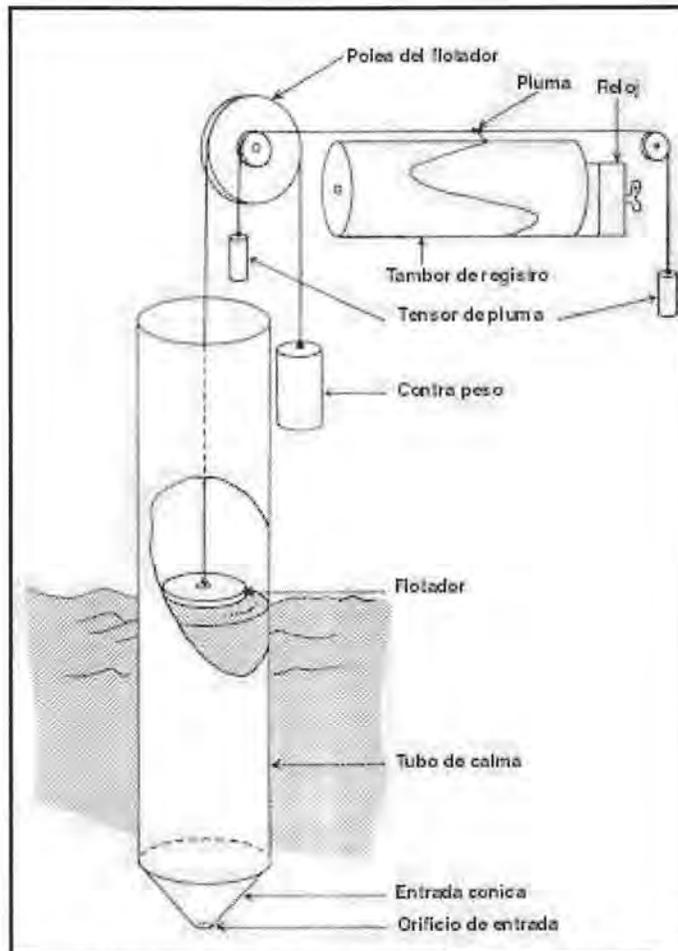


Figura 2-1 Mareógrafo simple de flotador

Todo mareógrafo de flotador es análogo al anterior solo difieren del modelo básico, modificando el mecanismo de operación para mejorar la exactitud y fiabilidad del sistema.

2.1.2 Mareógrafo de flotador con registro de cinta perforada

El funcionamiento de estos instrumentos es similar al descrito anteriormente, la diferencia está en la manera que la información es registrada. Estos instrumentos no dan un registro continuo del nivel de la marea sino alturas a intervalos de tiempo predeterminados, normalmente cada quince minutos. Estos instrumentos contienen una unidad que codifica el mecanismo del flotador. La unidad codificadora está diseñada para transferir la altura de agua hacia una cinta magnetofónica a cada periodo de tiempo. La elevación se perfora en la cinta en sistema binario como el mostrado en la Figura 2-2. Leer estos archivos a mano es particularmente laborioso y es necesaria la utilización de un lector automático para traducir la información sobre la cinta en una forma más práctica, segura y eficiente.

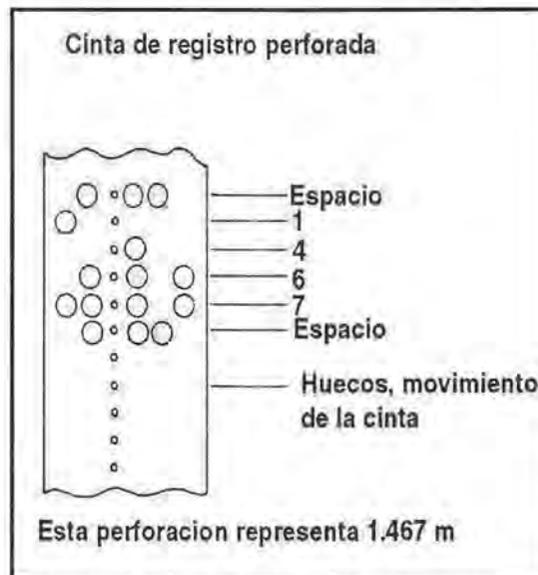


Figura 2-2 Registro de mareógrafo de flotador con cinta perforada

2.1.3 Mareógrafo neumático

Esta descripción se limita a mareógrafos que operan con sistemas de bombas neumáticas, como las mostradas en la Figura 2-3 donde se muestra el sistema básico de bombeo. El aire es introducido a una velocidad y volumen conocido a lo largo de un tubo de diámetro pequeño hasta el punto donde se requiere conocer la presión del agua. El dispositivo de presión normalmente tiene la forma de un pequeño cilindro vertical con la cara superior cerrada y abierta en el fondo. Un agujero pequeño se taladra aproximadamente a la mitad de la cara superior de manera que el tubo que conduce aire entre por este orificio. Como el aire del tubo entra en la cámara, comprime y empuja el agua debajo del tubo hasta desalojar toda el agua dentro de la cámara. La estabilidad de la presión se alcanza cuando toda el agua es desalojada, entonces con un dispositivo que mide la presión en el tubo se puede conocer la altura del agua, según la ley:

$$P_m = \delta gh + P_a \quad (5)$$

donde

- P_m presión manométrica conocida
- δ densidad del agua
- g aceleración de la gravedad
- h profundidad del agua sobre el dispositivo
- P_a presión atmosférica

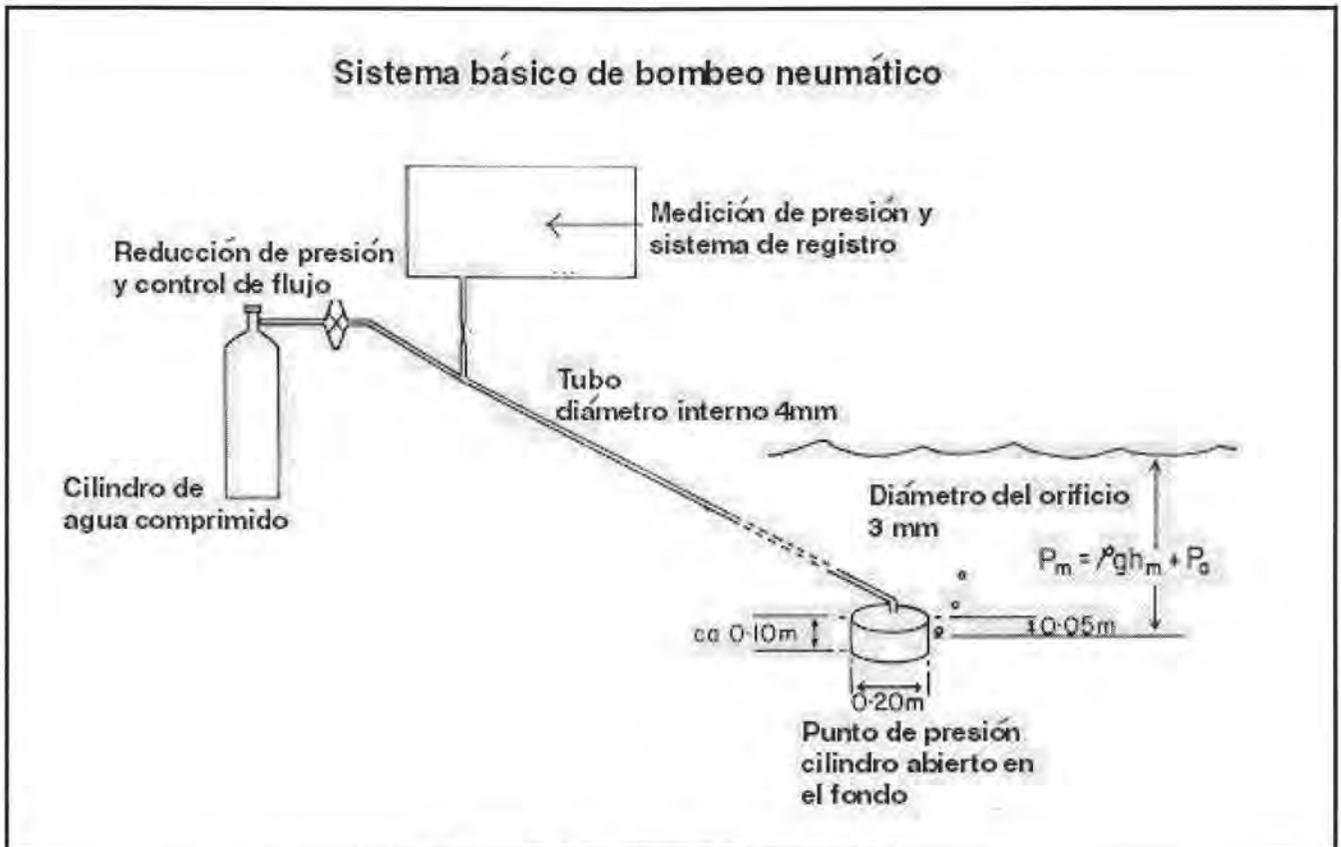


Figura 2-3 Mareógrafo neumático

2.1.4 Mareógrafo acústico

Con el desarrollo de la tecnología los mareógrafos también han avanzado en la forma de medir y adquirir los datos, por ejemplo el mareógrafo acústico, el cual consiste en medir el tiempo que tarda un pulso acústico en ser reflejado verticalmente entre la interfase del aire y la superficie del mar. Este tipo de medición puede hacerse al aire libre con el transductor acústico montado verticalmente sobre la superficie del mar, pero en ciertas condiciones los signos reflejados pueden perderse. Para asegurar el correcto funcionamiento, los pulsos acústicos generalmente se propagan dentro de un tubo vertical que proporciona cierto grado de calma en la superficie. El promedio de varias medidas también tendrá un efecto de calma y darán una exactitud mejorada.

Convertir con precisión a altura del nivel del mar requiere el conocimiento de la velocidad de sonido entre el transductor acústico y la superficie libre del agua. La velocidad del sonido puede variar significativamente con cambios en temperatura y humedad (sobre 0.17% / °C) y alguna forma de compensación es necesaria para tener medidas del nivel de la superficie del mar exactas. El método más simple es medir la temperatura continuamente en un punto de la columna de aire, esto se usa para calcular la velocidad real del sonido a ser usada. Para la corrección por temperatura pueden requerirse varios sensores de temperatura en la columna de aire a diferentes niveles para obtener el gradiente de temperatura.

La Administración Oceánica y Atmosférica Nacional (The National Oceanic and Atmospheric Administration NOAA), y el Servicio Nacional del Océano (National Ocean Service NOS) de los Estados Unidos Americano (USA), han estado involucrados en la implementación de la siguiente generación de un sistema de medición del nivel del mar, por sus siglas en inglés (Next Generation Water Level Measurement System **NGWLMS**). Se contaba en octubre de 1992 dentro de la red de mediciones de marea nacional americana con 110 estaciones y 22 alrededor del mundo con estos nuevos sistemas.

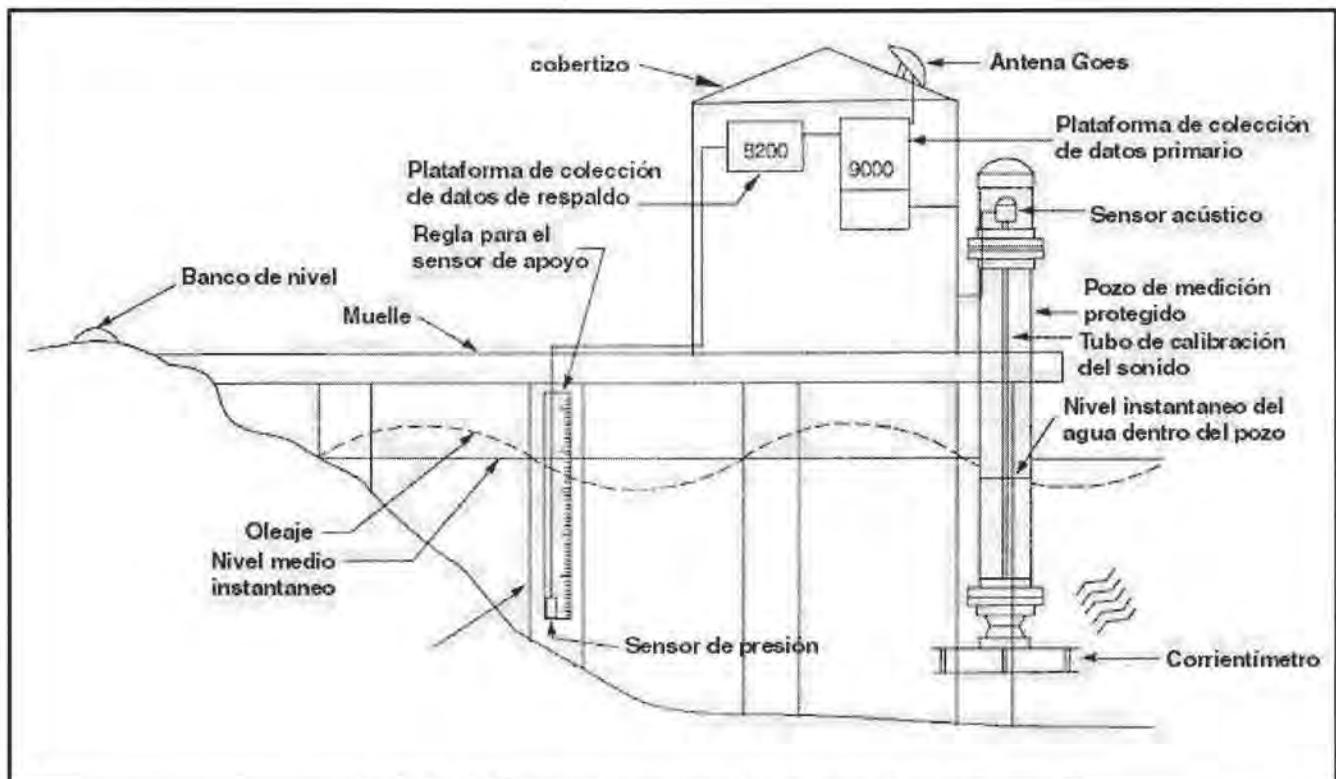


Figura 2-4 Siguiete generación de mareógrafos

Los mareógrafos de NGWLMS cuentan con un sensor para el nivel de agua Aquatrak (Dartex Inc.) con un sistema de proceso y transmisión de datos Stevens o Sutron. El sensor Aquatrak envía una serie de impulsos acústicos al tubo de calibración de sondeo y mide el tiempo que tarda el sonido en ser reflejado al punto de calibración de referencia y a la superficie del agua. Dos sensores de temperatura proporcionan el gradiente de temperatura dentro del

tubo. Los puntos de calibración de referencia permiten corregir la altura de la superficie del agua debido a cambios de temperatura. Cuenta con un sistema de respaldo que es un sensor de presión referido a un banco de nivel y una plataforma de colección de datos, los cuales son enviados por telemetría o por satélite a un centro de acopio. Las medidas de nivel del mar de un mareógrafo son frecuentemente requeridas para su uso en alguna parte diferente al sitio donde se obtiene la medición. El método de transmisión de datos depende mucho del tiempo de respuesta requerido y la distancia involucrada. La escala de tiempo puede variar de información casi instantánea a un año de grabación o mayor y la escala de distancias de unos cientos de metros a miles de kilómetros.

Para escalas de tiempo largas es posible transferir las grabaciones físicamente sobre cualquier distancia, pero para escalas de tiempo corto puede ser necesario transferir los datos en forma de señales eléctricas. Esto puede ser hecho con líneas telefónicas dedicadas o compartidas con la red telefónica pública, por conexión directa de radio, por conexión de satélite o por una combinación de éstas.

Los datos de instalaciones mareográficas remotas o inaccesibles o de redes mareográficas nacionales o internacionales pueden ser transmitidos por sistemas satelitales geoestacionarios u orbitales. Un número adecuado de sistemas satelitales están disponibles para su uso como son los sistemas ARGOS, GOES, METEOSAT, GMS e IMARSAT cada uno con diferentes características.

El sistema ARGOS es un sistema que opera mundialmente usando dos satélites con periodo de 101 minutos. Con la capacidad de transmisión de datos de 256 bits por cada paso del satélite y, dependiendo de la posición pueden tener un retraso de varias horas, antes de que los usuarios puedan disponer de los datos. El número de pasos accesibles puede variar dependiendo de la latitud, variando de aproximadamente 7 por día para el ecuador a 28 por día en los polos.

Los sistemas GOES-E (USA), GOES-W (USA), METEOSAT (Europa) y GMS (Japón) son satélites ecuatorianos geoestacionarios, los cuales juntos ofrecen cobertura mundial compatible, excepto para latitudes mayores a 75° y los datos pueden estar disponibles a los usuarios aproximadamente después de una hora de medición.

El sistema INMARSAT estándar C también usa satélites ecuatorianos geoestacionarios para dar cobertura mundial, excepto para latitudes mayores de 75°. Este sistema permite comunicación cercana a tiempo real a un rango de 600 bits por segundo con un tamaño del mensaje arriba de 256 Kbytes.

2.2 Estaciones mareográficas en la republica mexicana

En la Republica Mexicana existen varias instituciones gubernamentales que tienen instalados mareógrafos en los puertos de los estados como: la Secretaria de Marina, el Centro de Investigación Científica y de Educación Superior de Ensenada (CICESE) y el Instituto de Geofísica de la UNAM.

La Red de Monitoreo del Nivel del Mar del CICESE está constituida actualmente por 7 Estaciones Mareográficas distribuidas estratégicamente en las costas de la Península de Baja California y de algunos estados e islas de la República Mexicana que colindan con el Océano Pacífico. Se tiene programado instalar 3 estaciones más (en preparación) así como otras 5 (de reciente adquisición) para totalizar 15 a finales del 2004. La Figura 2-5 muestra la localización de las estaciones mareográficas del CICESE, la Figura 2-6 muestra la localización de 33 estaciones de la secretaria de Marina y la Figura 2-7 muestra la red mareográficas del Instituto de Geofísica de la UNAM la cual históricamente ha sido muy importante.

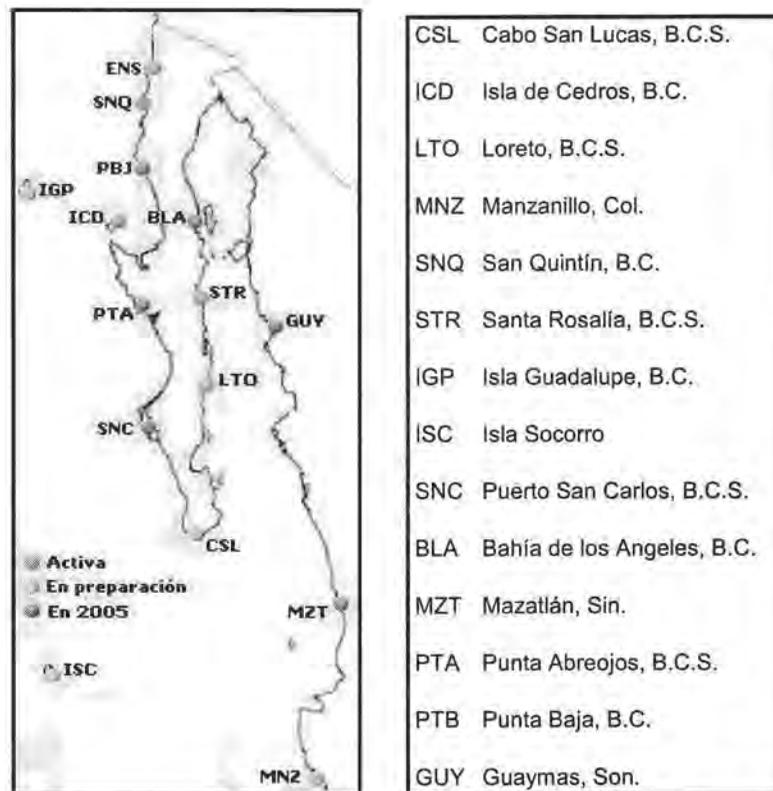


Figura 2-5 Localización estaciones mareográficas del CICESE

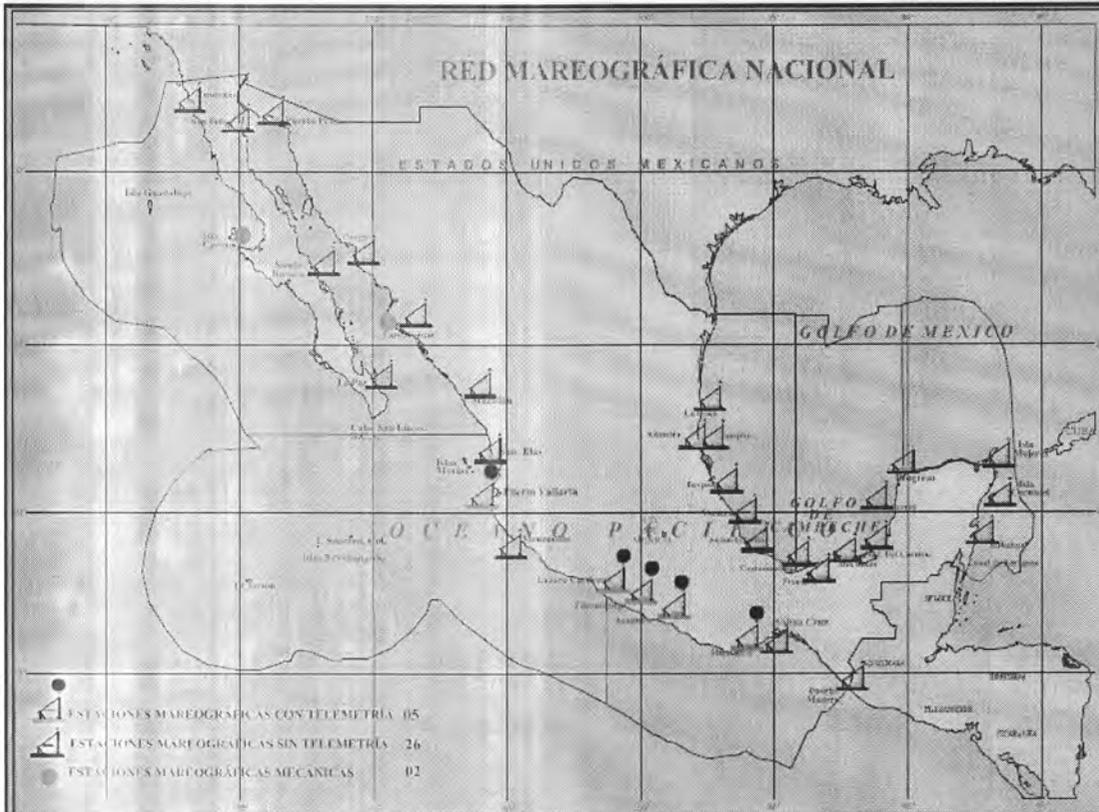


Figura 2-6 Localización estaciones mareográficas Secretaria de Marina



Figura 2-7 Localización estaciones mareográficas Instituto de Geofísica UNAM

3 *Métodos de predicción*

Tratar de conocer lo que pasará en un futuro, ha sido siempre una inquietud que el ser humano ha tenido desde tiempos remotos, con el fin de mejorar su seguridad y calidad de vida. Tratar de saber si el día de mañana lloverá o si caerá una helada o en general como será el clima para el día siguiente o para la semana siguiente, significaría en la agricultura asegurar las cosechas para obtener el mayor beneficio y consecuentemente en el mercado conocer el precio de los productos, significaría una mejor planeación de la economía.

Con cierto grado de incertidumbre en tiempos pasados el ser humano fue capaz de predecir la temporada de lluvias, la temporada de calor, y de una manera empírica o de una manera más formal, con la observación de los cuerpos celestes cual es la mejor temporada para sembrar o para realizar una actividad específica.

En la actualidad aun seguimos tratando de predecir el futuro desde una perspectiva basada en experiencias pasadas y simples conjeturas, hasta las predicciones basadas en métodos bastante complicados y laboriosos. Tratar de prever lo que pasara en un futuro cercano, incluye eventos de tipo natural como el clima para beneficio de la población, hasta eventos artificiales, como apuestas y juegos de azar para beneficio económico del jugador o simplemente para satisfacción personal, probando de esta manera su conocimiento de los hechos o su capacidad para relacionar los eventos actuales y hacer conjeturas correctas del futuro. Sin embargo todas estas predicciones o conjeturas tienen un mayor o menor grado de incertidumbre, en algunos casos la experiencia y la habilidad de relacionar las situaciones actuales puede ser más acertada que un análisis formal y laborioso. En algunas ocasiones es totalmente al contrario y en la mayoría de los casos el análisis formal es más confiable, pero en ninguno de los dos es 100% confiable. Lo anterior hace que las predicciones siempre tengan un margen de error, en algunos casos aceptable y útil a la sociedad y en otros casos no. Por lo tanto se busca que los métodos y técnicas de predicción siempre tengan un margen de error mínimo aceptable para que puedan considerarse confiables y sean considerados en la toma de decisiones. El aceptar un margen de error alto puede significar grandes pérdidas humanas y económicas lo cual muestra la importancia de la exactitud y consistencia de las predicciones.

A continuación se dará una breve descripción de los métodos de predicción que existen, así como su clasificación de acuerdo a los datos utilizados, el evento que se trate de predecir y el método utilizado para analizar los datos e inferir el resultado. Para un mejor entendimiento de la clasificación de los métodos, se presenta la **Figura 3-1** en forma de diagrama de árbol, donde se puede observar la relación que existe entre los datos, el evento y el método de predicción.

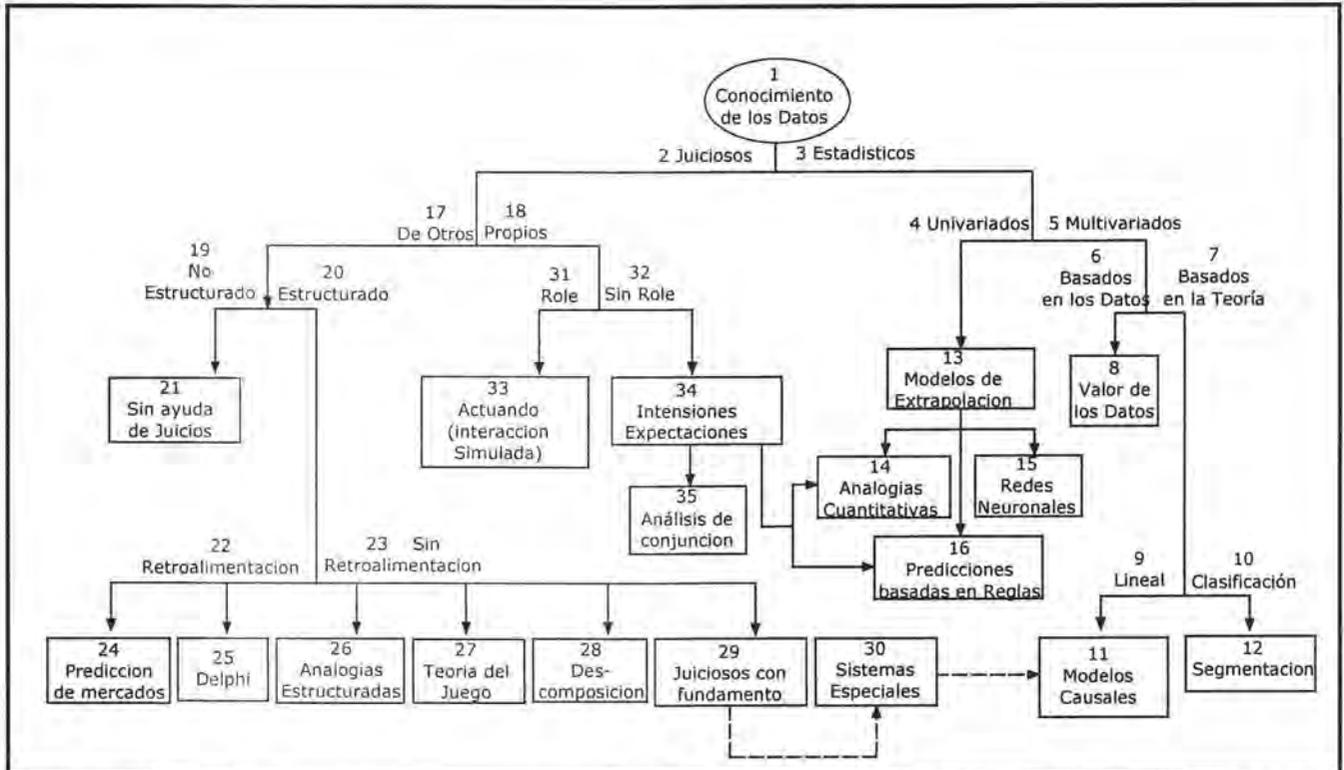


Figura 3-1 Árbol de metodologías para predicción. Clasifica los posibles tipos de predicción y métodos dentro de categorías y como se relacionan con otros. Las líneas punteadas representan posibles relaciones.

A continuación se describe en forma breve lo que significa cada punto del diagrama de árbol de acuerdo al número que le corresponde.

1. **Conocimiento de los datos:** Deben usarse datos fiables. También podrían usarse métodos subjetivos
2. **Métodos juiciosos:** Los datos numéricos disponibles son inadecuados para un análisis cuantitativo, es probable que la información cuantitativa incremente la exactitud, relevancia o aceptabilidad de las predicciones.
3. **Métodos estadísticos:** Datos numéricos disponibles y fiables.
4. **Datos univariados:** Los datos históricos están disponibles en el comportamiento que se va a predecir; por ejemplo los datos de las ventas de automóviles de 1940 a 2002.
5. **Datos multivariados:** Los datos están disponibles en variables que podrían afectar el comportamiento de interés.
6. **Modelos basados en los datos:** Experiencia o investigaciones anteriores no están disponibles así que se intenta inferir la relación de los datos.

7. **Modelos basados en la teoría:** Experiencia e investigación anteriores están disponibles y proporcionan información útil acerca de la relevancia en relación de la predicción.
8. **Modelos del valor de los datos:** Permitir que los datos se describan por si mismos. La teoría no es considerada.
9. **Modelos lineales:** El problema puede ser modelado con parámetros lineales.
10. **Modelos de clasificación:** El problema está compuesto por grupos que actúan de diferente forma en respuesta a un cambio, uno puede estudiar cada grupo separadamente, después agregar los resultados por segmentos; por ejemplo, en la industria aérea, el precio tiene un efecto diferente en los negocios y en el turismo.
11. **Modelos causales:** Teoría, investigación previa y conocimiento experto del dominio son usados para especificar la relación entre una variable para ser estimada y las variables conocidas. En el caso de métodos de la economía, se usa comúnmente el análisis de regresión para estimar los coeficientes del modelo ya que ellos son consistentes con el conocimiento adquirido anteriormente. La relación entre los sistemas de modelos dinámicos usan acciones y flujos, frecuentemente con un énfasis en ciclos de autoalimentación. Los modelos causales se utilizan para proporcionar mayor exactitud en las predicciones económicas.
12. **Modelos de segmentación:** Cuando los segmentos son independientes, una estructura de árbol es apropiada. Cuando la información esta disponible en la relación entre segmentos, un análisis de entrada-salida, sistemas dinámicos o análisis de grupo pueden ser usados. De las técnicas de dependencia entre grupos, solo el análisis de entrada-salida ha sido encontrada que proporciona mayor exactitud en las predicciones.
13. **Modelos de extrapolación:** Usan datos de series de tiempo o datos similares del corte de una sección, por ejemplo, el suavizado exponencial es usado para extrapolar en el tiempo.
14. **Analogías cuantitativas:** Los expertos identifican situaciones análogas para los que las series de tiempo están disponibles y obtienen el rango de similitud de cada analogía a la situación que tiene una cantidad pobre de datos. Estos datos de entrada se usan para derivar una predicción. Por ejemplo para predecir la demanda de lugares en un cinema de un nuevo suburbio, podrían usarse los datos promedio de otros suburbios, identificados por los especialistas como similares para el objetivo.
15. **Redes neuronales:** Las predicciones con redes neuronales han recibido creciente interés en varios campos de investigación y dominios de aplicación debido a su enorme potencial de manejar datos contaminados con ruido, en la actualidad se pueden utilizar con un buen grado de exactitud en el reconocimiento de imágenes, filtrado de señales etc. Las redes neuronales no se han establecido todavía como un

método válido y fiable en el dominio de predicciones de negocios, o en un nivel estratégico, táctico u operacional.

16. **Modelos de predicción basados en reglas:** Requiere conocer especialmente el dominio y la combinación de técnicas estadísticas, usando un sistema especial de series de tiempo. Las características de las series de tiempo son identificadas por análisis automático pero los especialistas identifican algunos factores. En particular identifican las fuerzas que causan la acción o la tendencia y las reglas que combinan adecuadamente métodos de predicción, como métodos de extrapolación, regresión lineal y suavizado exponencial, con técnicas estadísticas.
17. **Otros:** Volviendo a los métodos de predicción juiciosos, se refiere a otros, cuando existe el conocimiento del comportamiento o conducta esperada de otras personas u organizaciones.
18. **Propios.** Las personas tienen intenciones válidas o expectativas sobre su conducta. Las dos son muy útiles cuando: 1 pueden obtenerse muestras representativas, 2 las respuestas están basadas en un buen conocimiento, 3 no hay razón para mentir, 4 la nueva información es improbable que cambie el comportamiento. Las intenciones están más limitadas que las expectativas y son útiles cuando: el evento es importante, el comportamiento es planeado y los encuestados pueden llenar completamente la encuesta. Por ejemplo, el comportamiento no es dependiente de que otras personas estén de acuerdo o no.
19. **No estructurado:** La información es usada en una manera informal.
20. **Estructurado:** Métodos formales son usados para analizar la información. Esto significa que las reglas para análisis están escritas de antemano y se siguen rigurosamente. Deberán guardarse archivos del procedimiento que fue hecho.
21. **Sin ayuda de juicios:** Los expertos piensan acerca de una situación y predicen el comportamiento de las personas. Ellos podrían tener acceso a datos y consejos, pero sus predicciones no están ayudadas o soportadas por métodos formales. Este es el método comúnmente más usado. Este método es rápido, barato cuando solo unas pocas predicciones son necesarias, y pueden ser usadas cuando pequeños cambios son esperados. Probablemente, sea más útil cuando el pronosticador consigue acertar y hay una retroalimentación acerca de la exactitud de su predicción, por ejemplo el boletín meteorológico, deportes y apuestas de juegos de naipes.
22. **Retroalimentación:** Un procedimiento formal es usado para solicitar u obtener peso y combinar predicciones de las personas. El procedimiento deberá desarrollarse anteriormente a las predicciones y deberá seguirse rigurosamente.

23. **Sin retroalimentación:** Procedimientos formales son usados para ayudar a la gente a recuperar y organizar su información acerca de la situación de la predicción. Esta información es entonces analizada usando reglas preestablecidas.
24. **Mercados de predicción:** Las personas apuestan en lo que pasará (casas de bolsa). Los mercados pueden ser útiles cuando la información es ampliamente dispersa. Tal como una elección política.
25. **Técnica Delphi:** Las predicciones y razonamiento de especialistas es colectada y resumida por un moderador para proporcionar anónima retroalimentación sobre al menos dos rondas. Los especialistas revisan y ven el ajuste y la predicción es combinada.
26. **Analogías estructuradas:** Un experto lista analogías para un objetivo, describe similitudes y diferencias, rangos de similitud y une cada decisión con su analogía, con un potencial objetivo de la situación decidida.
27. **Teoría del juego:** Análisis formal del comportamiento de dos partes con intereses divergentes en situaciones que pueden ser descritas por reglas.
28. **Descomposición:** El problema es direccionar en partes. Las partes pueden ser multiplicativas o aditivas. Por ejemplo, para prever las ventas de una marca, se podrían estimar las ventas del mercado totales y parciales (multiplicativas) o podrían hacerse estimaciones para cada tipo de artículo al prever nuevas ventas del producto para una división (aditiva).
29. **Juiciosos con fundamento:** Deriva en un modelo del conocimiento de predicciones de expertos y los factores que ellos usaron para hacer sus predicciones usando análisis de regresión. Útil cuando los juicios de los especialistas, tienen validez pero los datos son escasos y donde el factor importante no cambia en los datos históricos, como cuando se intenta estimar la variabilidad del precio usando series de tiempo con una pequeña variación en el precio.
30. **Sistemas especiales:** Reglas para predicciones son derivadas del razonamiento que usan especialistas cuando hacen predicciones, se obtiene conocimiento de diversas fuentes tales como encuestas, entrevistas, análisis de discusiones e investigación de artículos y publicaciones.
31. **Con rol (actuación, papel):** El papel o role de las personas influye en su comportamiento y hay conocimiento sobre estas actuaciones.
32. **Sin rol:** El papel de las personas se espera no influya en su comportamiento, o no se sabe el papel de las personas o hay muchos actores con diferentes papeles.
33. **Actuando (interacción simulada):** Se espera que las personas piensen de manera consistente con el papel que están desempeñando y la situación descrita para ellos. Esto incluye interactuar con personas con diferentes papeles con el propósito de

predecir el comportamiento de los protagonistas reales. A esto se le llama interacción simulada. Esto es, personas que representan probables interacciones de una manera realista. Las decisiones de los actores son usadas para predecir las decisiones reales.

34. Intenciones/Expectativas: Se encuesta a las personas acerca de sus intenciones o expectativas que consideran para su futuro comportamiento o los de su organización. Analiza los datos obtenidos para derivar predicciones.

35. Análisis de conjunción: Elije preferencias de usuarios (u otros actores) para varios ofrecimientos. Por ejemplo, las alternativas para el diseño de computadoras. Usando combinaciones de características como la capacidad y peso de una computadora portátil. Después son usados análisis de regresión para predecir el diseño más aceptable.

Todos estos modelos intentan conocer el comportamiento o resultado de alguna cuestión en particular.

Enfocando la atención en los métodos de datos estadísticos univariados. Estos ocupan generalmente, modelos lineales para realizar la predicción, los cuales no describen exactamente el comportamiento de ciertos fenómenos. En este sentido, algunos nuevos modelos y métodos han sido propuestos, los cuales son capaces de tomar en cuenta la no linealidad de las series de tiempo, tales como las **redes neuronales artificiales**, procesos estocásticos no lineales **GARCH** (Engle 1982; Bollerslev, 1986), modelos determinísticos no lineales como **dinámica del caos** (Trippi, 1995), **análisis no paramétrico** (Diebold y Nason, 1990) y **ajuste de regresión adaptativa multivarida** (Lewis, Ray and Stevens, 1994) etc.

Un campo que ha recibido una amplia atención en los últimos años en la literatura es el de **sistemas de dinámica compleja y caos determinístico**, los cuales pueden proveer una herramienta completa en la predicción de series de tiempo financiera. El principal propósito de los sistemas dinámicos no lineales es para manejar procesos complejos usando modelos determinísticos. El interés en esta área es que se ha encontrado que simples modelos determinísticos de sistemas dinámicos, pueden producir un movimiento complicado que exhibe las características del comportamiento aleatorio (comportamiento caótico o del caos).

Un sistema caótico es aquel en el cual la predicción de periodos largos de la trayectoria del sistema es imposible ya que cualquier incertidumbre en su estado inicial crece exponencialmente rápido en el tiempo. Esta característica es llamada dependencia sensitiva de las condiciones iniciales, y es la razón de la pérdida rápida de la exactitud en la predicción en sistemas caóticos. Sin embargo el proceso caótico es determinista y muestra una clara diferencia con los procesos aleatorios.

De los modelos de predicción antes mencionados, este trabajo enfoca la atención en los modelos de redes neuronales artificiales por su capacidad en el manejo de datos con ruido, porque estos modelos aprenden de la experiencia, el buen desempeño en el manejo de la información oceanográfica y su destacado potencial de predicción en comparación de otros métodos. Una comparación entre los métodos tradicionales y las redes neuronales se puede encontrar en Pitarque et al., 1998. En la tarea de predicción de este trabajo, los resultados

muestran que no hay gran diferencia entre las redes neuronales y los modelos estadísticos siempre y cuando los datos estadísticos muestren un buen patrón de correlación lo que generalmente no sucede. En la tarea de clasificación los resultados favorecen claramente a las redes neuronales sobre los modelos estadísticos clásicos como técnicas de clasificación, afirmación que se ve fortalecida por su mayor versatilidad de uso, al no depender su aplicabilidad del cumplimiento de los supuestos teóricos sobre los que se basan las técnicas estadísticas (normalidad, homogeneidad, independencia, etc.). Otra ventaja adicional (importante en investigación aplicada) de las redes neuronales sobre los modelos estadísticos es que admiten como variables de entrada conjuntos mixtos de variables cuantitativas y cualitativas.

Otros estudios muestran a las redes neuronales como técnicas estadísticas no paramétricas al estar libres del cumplimiento de los supuestos teóricos de la estadística paramétrica (Smith, 1993), o también como técnicas de regresión no lineal (Sarle, 1998). El problema surge cuando encontramos resultados contradictorios a la hora de determinar qué modelos son más eficientes en la solución de problemas concretos de predicción/clasificación. Así mientras algunos trabajos empíricos no encuentran diferencias entre los resultados hallados por unos y otros modelos (Croall y Mason, 1992; Michie et al, 1994; Ripley, 1993; Thrun, Mitchell y Cheng, 1991), otros resultados tienden a apoyar una ligera superioridad de las redes neuronales sobre las técnicas estadísticas (Garson, 1991; Huang y Lippman, 1987; White, 1994). Los estadísticos explican estas discrepancias empíricas aduciendo una incorrecta aplicación de las técnicas estadísticas: análisis inadecuado de los supuestos teóricos en los que se basan (homogeneidad de la matriz de covarianzas, normalidad, etc.), utilización de matrices de datos sesgados, ausencia de pre-procesamiento de los datos (outliers, missing data, etc.) y transformación de variables, etc. Por su parte los expertos en redes aducen que pese a que las redes neuronales a priori son capaces de asociar cualquier patrón de entrada con cualquier patrón de salida, su rendimiento depende del ajuste heurístico de numerosos parámetros (número de unidades de entrada, salida y número de unidades ocultas, funciones de activación: lineal, sigmoidea, tangencial, etc.; regla de aprendizaje: Hebb, delta, retropropagación, coeficientes de aprendizaje y momentum, etc.), ajuste que no siempre garantiza la solución deseada.

De lo anterior no se desprende el destierro de los métodos estadísticos convencionales a la hora de realizar tareas de clasificación y predicción, pues las redes neuronales, pese a su mejor rendimiento, presentan una serie de inconvenientes que el investigador debe de sopesar antes de decidirse por su utilización. En primer lugar, el entrenamiento de una red neuronal es un proceso demasiado creativo (Martín y Sanz, 1997) que generalmente se soluciona por un método heurístico de ensayo y error. Además, y esto es un aspecto especialmente delicado, la calidad de las soluciones dadas por la red elegida no puede ser siempre garantizada (Cherkassky et al, 1994) debido a su naturaleza de "caja negra" y otras causas: interferencia catastrófica, sobreaprendizaje, mínimos locales, etc. No hay que olvidar tampoco que una red neuronal no da información explícita sobre la importancia relativa de los distintos predictores. Ni, por último, obviar el elevado costo computacional requerido en el entrenamiento de las redes neuronales, muy superior al de los modelos estadísticos.

Tomando en cuenta los aspectos anteriores y los estudios efectuados recientemente con redes neuronales aplicados a la ingeniería costera para predecir niveles de agua (Tissot et al 2001), (Bowles et al. 2003), (Vaziri 1997), mareas horarias (Tsai and Lee 1999), respuesta de estructuras costeras (Mase et al. 1995) entre otros estudios donde reportan el buen funcionamiento de las redes neuronales en comparación con los métodos estadísticos, se decidió en este trabajo la utilización del modelo con redes neuronales artificiales para la predicción de marea meteorológica.

4 *Introducción a redes neuronales artificiales*

4.1 **Historia**

Aunque el estudio del funcionamiento del cerebro junto con las neuronas ha sido estudiado ampliamente, los científicos aun no han conseguido un completo conocimiento del funcionamiento de las neuronas biológicas; sin embargo la memoria es considerada como la interconexión entre ellas y el aprendizaje como nuevas conexiones y modificación de las existentes.

Las neuronas que se tratarán en este trabajo son abstracciones de las neuronas biológicas y son concebidas como elementos en un programa de computadora y en otros trabajos son circuitos hechos de silicón. Las redes de estas neuronas artificiales no tienen ni una fracción del poder del cerebro humano, sin embargo estas pueden ser entrenadas para ejecutar adecuadamente tareas y resultados útiles a la sociedad.

La historia de las redes neuronales artificiales (RNA) ha evolucionado a través del tiempo debido a su desarrollo en conceptos, innovación e implementación. El desarrollo del campo de RNA ocurrió recientemente en el siglo XIX y XX. Esto consistió principalmente de trabajos interdisciplinarios en física, psicología y neurofisiología, por científicos tales como **Hermann von Helmholtz**, **Ernst Mach** e **Ivan Pavlov**. Estos primeros trabajos enfatizaron teorías generales de aprendizaje, visión y acondicionamiento, y no incluían modelos matemáticos específicos de la operación de las neuronas.

El desarrollo moderno de las RNA comenzó en los años 1940's con el trabajo de Warren McCulloch y Walter Pitts (1943), quienes mostraron que las RNA podían en un principio, calcular cualquier función aritmética o lógica. Por lo tanto su trabajo es considerado como el origen del campo de las redes neuronales artificiales. McCulloch y Pitts fueron seguidos por Donald Hebb, (1949), quien propuso un mecanismo de aprendizaje en las neuronas biológicas.

La primera aplicación practica de las RNA llego en los años 1950's, con la invención de una red perceptron y regla de aprendizaje asociativa hecha por Frank Rosenblatt (1958). Rosenblatt y sus colegas construyeron una red perceptron y demostraron su habilidad para ejecutar patrones de reconocimiento. Este primer suceso genero un gran interés en trabajos de investigación en RNA. Desafortunadamente, se mostró más tarde que la red de perceptron básica solo podía resolver un una clase limitada de problemas.

Al mismo tiempo, Widrow y Hoff (1960), introducían un nuevo algoritmo de aprendizaje y usaron este para entrenar redes lineales adaptativas, el cual era similar en estructura y capacidad que el perceptron de Rosenblatt. La regla de aprendizaje Widrow-Hoff aun esta en uso hoy en día. Desafortunadamente ambas redes sufrían de la misma e inherente limitación (solo podían resolver una clase limitada de problemas). Rosenblatt y Widrow estaban concientes de esta limitación y propusieron nuevas redes que pudieran superar a las

anteriores. Sin embargo no pudieron lograr modificar sus algoritmos de aprendizaje para entrenar redes más complejas.

Ambas redes fueron ampliamente criticadas por Marvin Minsky y Seymour Papera (1969). Mucha gente influenciada por Minsky y Papert, creyeron que el futuro de las redes neuronales estaba en vías de extinción. Esto junto con el hecho que no había computadoras con la capacidad necesaria en la cual realizar los experimentos hizo que muchos investigadores abandonaran el campo. Por una década la investigación en RNA fue abandonada.

Sin embargo algunos importantes trabajos continuaron durante los años 1970's. En 1972 Teuvo Kohonen y James Anderson, desarrollaron nuevas redes neuronales que podían actuar como memoria. Stephen Grossberg estuvo también muy activo durante este periodo en la investigación de redes auto-organizativas.

Aunque el interés en redes neuronales estuvo abandonado durante los años 1960's. Durante los años 1980's, con las nuevas computadoras personales y estaciones de trabajo junto con su rápido crecimiento en capacidad, los dos impedimentos anteriores fueron superados y los investigadores en redes neuronales se incrementaron dramáticamente, en adición de que importantes nuevos conceptos fueron introducidos.

Principalmente dos nuevos conceptos fueron responsables del renacimiento de las redes neuronales. El primero fue el uso de mecanismos estáticos para explicar la operación de ciertas clases de redes recurrentes, las cuales podían ser usadas como una memoria asociativa (J. J. Hopfield, 1982)

El segundo desarrollo importante de los 1980's fue el algoritmo de retropropagación para entrenar redes multicapas de perceptron, el cual fue descubierto independientemente por varios investigadores. La publicación que tuvo más influencia del algoritmo de retropropagación fue realizada por David Rumelhart y James McClelland (1986). Este algoritmo fue la respuesta a las criticas hechas por Minsky y Papert en los 1960's. Estos nuevos conceptos revigorizaron el campo de redes neuronales en los últimos 10 años, lo que propicio que cientos de artículos se hayan escrito y las redes neuronales hayan encontrado muchas aplicaciones.

4.2 Inspiración biológica

Las redes neuronales artificiales (RNA) son solo representaciones remotas de su contra parte biológica, son sistemas paralelos para el procesamiento de la información, inspirados en el modo en el que las redes neuronales biológicas del cerebro procesan la información.

El cerebro consiste de un numero de aproximadamente 10^{11} elementos altamente interconectados (aproximadamente 10^4 conexiones por elemento) llamados neuronas. A grandes rasgos las neuronas se componen de tres partes fundamentales: las dendritas, el cuerpo de la célula y el axón. Las dendritas son redes receptivas como árboles de fibra nerviosa que acarrear señales eléctricas dentro del cuerpo de la célula. El cuerpo de la

célula suma y procesa esas señales de entrada. El axón es una simple fibra nerviosa larga que lleva la señal del cuerpo de la célula a otra neurona. El punto de contacto entre un axón de una célula y una dendrita de otra célula es llamado sinapsis. Este arreglo entre las neuronas representa el umbral de entrada y esta determinado por un complejo proceso químico que establece el funcionamiento de la red neuronal, un esquema de la neurona biológica se presenta en la Figura 4-1.

Una parte de la estructura neuronal es definida en el nacimiento. Otras partes son desarrolladas a través del aprendizaje con nuevas conexiones entre las neuronas y otras modificando las existentes. Algunas conexiones deben realizarse después del nacimiento a temprana edad si esas conexiones no son realizadas el individuo no podrá desarrollar en una edad más avanzada la capacidad que le dan esas conexiones, ya que esas conexiones no podrán llevarse a cabo.

Como se menciona anteriormente, la diferencia entre una red neuronal biológica y una red neuronal artificial es muy grande pero las características que tienen en común son dos principalmente:

Biológicamente, un cerebro aprende mediante la reorganización de las conexiones sinápticas entre las neuronas que lo componen. De la misma manera, las RNA tienen un gran número de procesadores virtuales interconectados que de forma simplificada simulan la funcionalidad de las neuronas biológicas. En esta simulación, la reorganización de las conexiones sinápticas biológicas se modela mediante un mecanismo de pesos, que son ajustados durante la fase de aprendizaje. En una RNA entrenada, el conjunto de los pesos determina el conocimiento de esa RNA y tiene la propiedad de resolver el problema para el que la RNA ha sido entrenada.

Por otra parte, en una RNA, además de los pesos y las conexiones, cada neurona tiene asociada una función matemática denominada función de transferencia. Dicha función genera la señal de salida de la neurona a partir de las señales de entrada. La entrada de la función es la suma de todas las señales de entrada por el peso asociado a la conexión de entrada de la señal, una representación de la neurona artificial se presenta en la Figura 4-2 donde se observa una semejanza con la neurona biológica en estructura y forma.

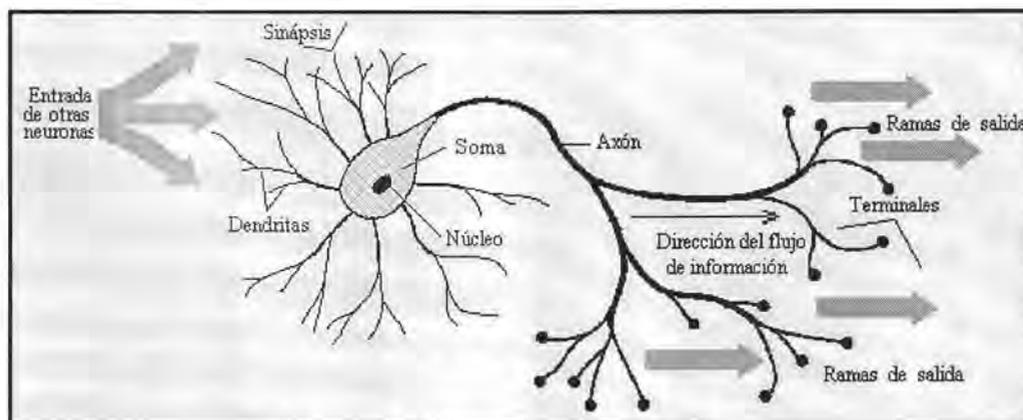


Figura 4-1 Esquema neurona biológica

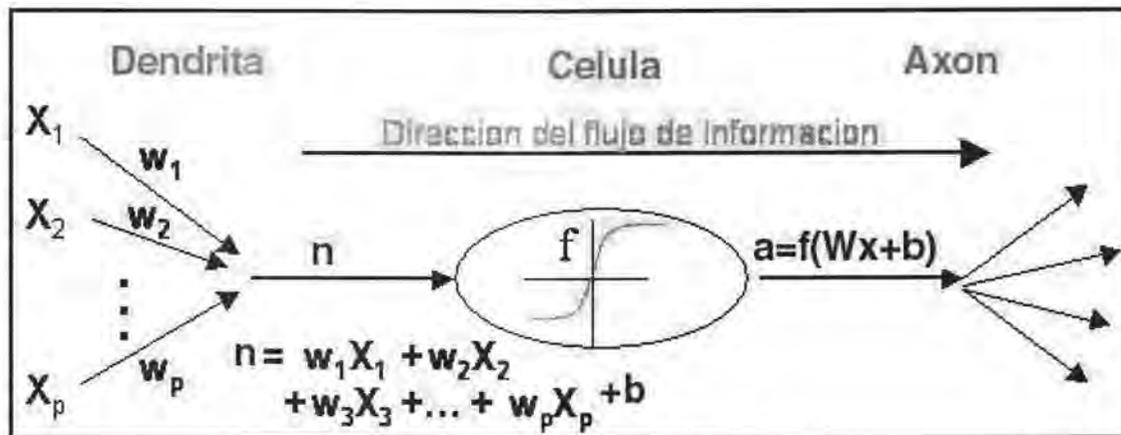


Figura 4-2 Esquema neurona artificial

4.3 Modelos neuronales artificiales

Los principales componentes de una red neuronal artificial son:

- Datos de entrada
- Vector o matriz de pesos
- Desviación o sesgo (bias)
- Número de capas intermedias
- Función o funciones de transferencia (Neurona)

Un modelo neuronal artificial es como el mostrado anteriormente en la **Figura 4-2**. Los datos de entrada del vector \mathbf{X} son multiplicados por el vector de pesos \mathbf{w} para formar el producto vectorial \mathbf{wX} que es uno de los términos de la sumatoria, el otro término de entrada es una desviación inicial o sesgo \mathbf{b} (bias) que es enviado a la sumatoria, el resultado de la sumatoria (\mathbf{n}) es entonces enviado a la neurona que contiene la función de transferencia o función de activación \mathbf{f} para obtener el resultado de salida (\mathbf{a}), que puede ir a otra neurona o al ambiente, el resultado de salida de la neurona se compara con el dato real (\mathbf{T}) y la diferencia ($\mathbf{T}-\mathbf{a}$) será el error. Si el error es mayor a una tolerancia dada el valor de los pesos y el valor del sesgo se tiene que modificar de manera que el error cada vez sea menor. **A esto se le llama entrenamiento** y en algunas ocasiones esto no es posible y una nueva condición tiene que ser dada, y esta es la cantidad del número de ciclos de entrenamiento. Una representación compacta y matricial es como la mostrada en la **Figura 4-3**. Donde se muestra un vector de entrada \mathbf{p} de R renglones, una matriz de pesos \mathbf{w} de S renglones por R columnas, un vector de sesgo \mathbf{b} de S renglones y un vector de entrada $\mathbf{n}=\mathbf{wp}+\mathbf{b}$ de S renglones, algunas funciones de transferencia son las mostradas en la Figura 4-4.

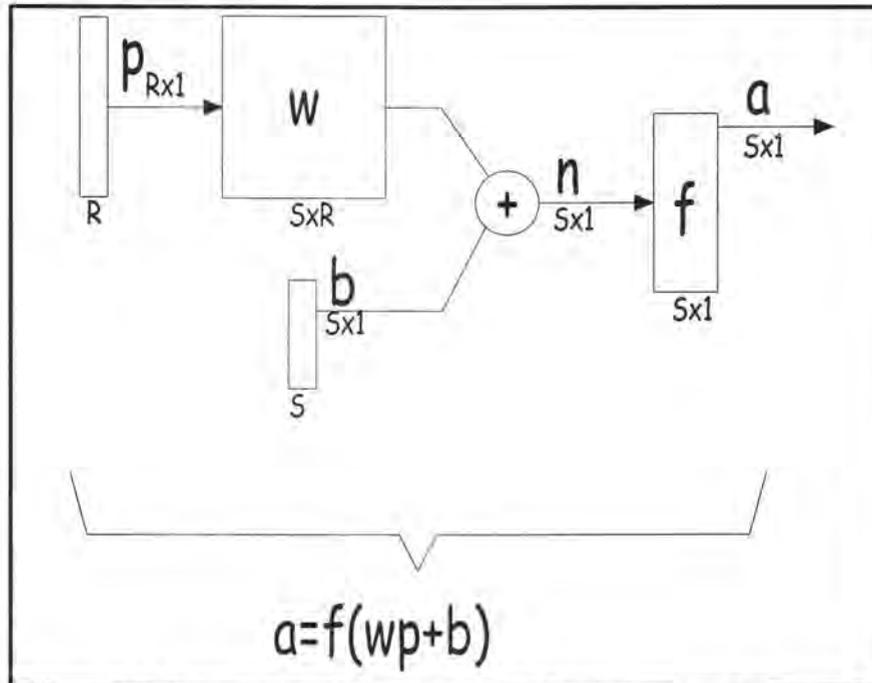


Figura 4-3 Representación gráfica y matricial de una red neuronal

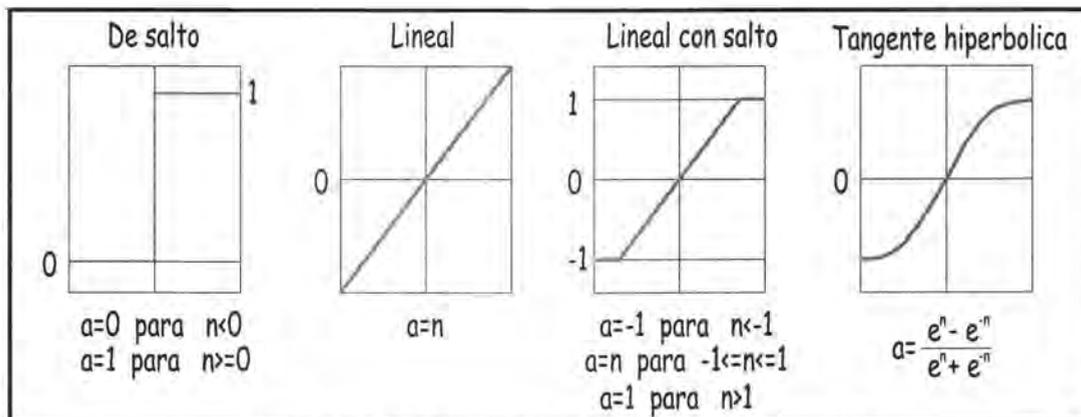


Figura 4-4 Principales funciones de transferencia

En la **Figura 4-3** se muestra un tipo sencillo de red neuronal, sin embargo existe una serie de modelos que varían en su arquitectura, que es: datos de entrada, número de capas intermedias, tipo y número de funciones de transferencia, los cuales pueden clasificarse:

1. De acuerdo al tipo de conexión que representa, en propagación hacia delante como puede ser el perceptrón simple y Adaline con una simple capa y perceptron multicapa
2. De acuerdo al tipo de aprendizaje si necesita o no un conjunto de entrenamiento supervisado. Para cada tipo de aprendizaje encontramos varios modelos propuestos por diferentes autores:
 - **Aprendizaje supervisado:** necesitan un conjunto de datos de entrada previamente clasificado y cuya respuesta objetivo se conoce. Ejemplos de este tipo de redes

son: el perceptrón simple, la red Adaline, el perceptrón multicapa y la memoria asociativa bidireccional.

- **Aprendizaje no supervisado** o autoorganizado: no necesitan de tal conjunto previo. Ejemplos de este tipo de redes son: las memorias asociativas, las redes de Hopfield, la máquina de Bolzman, la máquina de Cauchy, las redes de aprendizaje competitivo, las redes de Kohonen o mapas autoorganizados y las redes de resonancia adaptativa (ART)
- **Redes híbridas**: son un enfoque mixto en el que se utiliza una función de mejora para facilitar la convergencia. Un ejemplo de este último tipo son las redes de base radial.

3. Finalmente las RNA según sean capaces de procesar información de distinto tipo se pueden clasificar en:

- **Redes analógicas**: procesan datos de entrada con valores continuos y, habitualmente, acotados. Ejemplos de este tipo de redes son: Hopfield, Kohonen y las redes de aprendizaje competitivo.
- **Redes discretas**: procesan datos de entrada de naturaleza discreta; habitualmente valores lógicos booleanos. Ejemplos de este segundo tipo de redes son: las máquinas de Bolzman y Cauchy, y la red discreta de Hopfield.

A continuación se enumeran las principales redes neuronales existentes una descripción detallada de las mismas así como los algoritmos de entrenamiento se puede encontrar por ejemplo en Hagan, et al., (1996)

- Perceptrón simple
- Adaline
- Perceptrón multicapa
- Memorias asociativas
- Máquina de Bolzman
- Máquina de Cauchy
- Redes de Elman
- Redes de Hopfield
- Redes de neuronas de base radial
- Redes de neuronas de aprendizaje competitivo
- Redes de Kohonen o mapas autoorganizados
- Redes ART (Adaptative Resonance Theory)

En resumen una red neuronal adecuada para realizar cierto trabajo, consiste en encontrar la mejor arquitectura y el mejor método o algoritmo de entrenamiento. Sin embargo, éste trabajo no está enfocado en desarrollar una nueva arquitectura de red neuronal, ni tampoco en mejorar los algoritmos de entrenamiento, si no, de encontrar la mejor arquitectura existente para la predicción de mareas residuales o meteorológicas en periodos cortos de tiempo (12 a 24 horas).

5 *Modelo de predicción con redes neuronales*

Las redes neuronales han evolucionado notablemente y se han convertido en herramientas muy útiles para diferentes disciplinas. En particular, este trabajo centra su atención en la utilización de redes neuronales para la predicción de la marea meteorológica. En este capítulo se desarrolla una arquitectura capaz de predecir, con un buen grado de confiabilidad, la marea meteorológica que se puede presentar en algún lugar debida, como su nombre lo indica, a fenómenos meteorológicos (huracanes, nortes, depresiones tropicales, etc). De esta manera tendremos, por un lado, la predicción de marea astronómica con componentes armónicos y por otro, la predicción de marea meteorológica con redes neuronales. La suma de estas dos dará como resultado la marea total en el sitio de interés.

5.1 Antecedentes

El estudio y entendimiento de los procesos costeros, y en general, las ciencias oceánicas dependen fundamentalmente de observaciones de variables meteorológicas y oceanográficas. Por esta razón es de gran importancia que nuestro país cuente con una red de observación oceánica con recolección sistemática de datos atmosféricos y oceánicos durante largos periodos de tiempo que permitirá, entre otras cosas, hacer predicciones más exactas del clima, favorecer un manejo conveniente de las actividades pesqueras, hacer uso adecuado y eficiente de los recursos oceánicos no renovables y procurar la preservación del ecosistema marino y la biodiversidad del océano.

En agosto de 2003 surge el proyecto "Red de Observaciones y Predicción de Variables Oceánicas en las Costas y Puertos del Golfo de México" (ROPVO-GM). Patrocinado por CONACYT que tiene como principal objetivo poner en marcha un sistema confiable de medición y predicción de los niveles de la superficie libre del mar. Este proyecto contempla la instrumentación y adaptación de un sistema para la medición de las variables meteorológicas y del nivel del mar a lo largo de la costa de los Estados de Tamaulipas y Veracruz (ver Figura 5-1). Este sistema estará unido a las estaciones ya existentes de la Secretaría de Marina y el Instituto de Geofísica de la UNAM (ver Figura 2-6 y Figura 2-7) así como a las 42 plataformas de recolección de datos con las que cuenta la Texas Coastal Ocean Observation Network (TCOON), las cuales se indican en la Figura 5-2. De esta manera se cubre casi en su totalidad el Golfo de México y los datos estarán disponibles en tiempo cercano al real a través de Internet.

Otro de los objetivos del proyecto y que es tema de este trabajo, es la implementación de un modelo de predicción de marea basado en un modelo de red neuronal artificial, que tome en cuenta los efectos meteorológicos.



Figura 5-1 Localización estaciones mareográficas ROPVO-GM

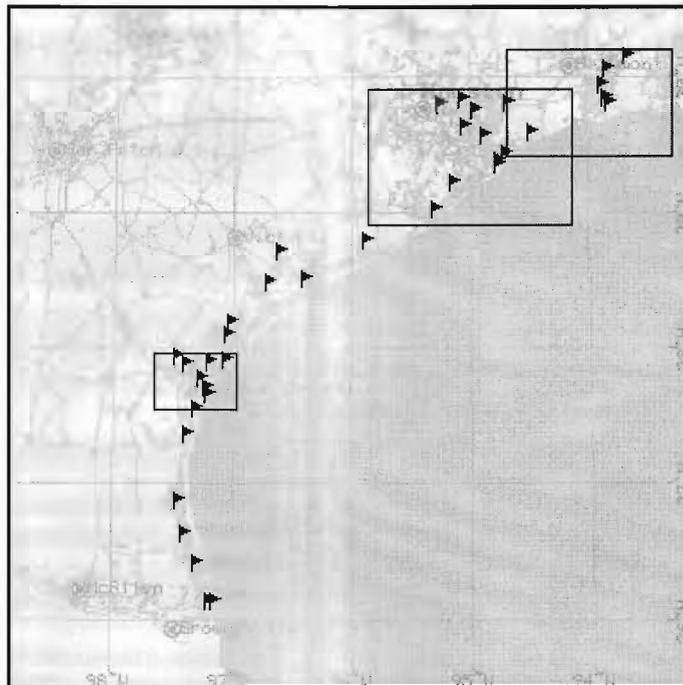


Figura 5-2 Localización estaciones mareográficas TCOON

5.2 Metodología

La metodología que se llevó a cabo y que se muestra en este capítulo para encontrar el mejor modelo de predicción de marea real (astronómica + meteorológica), se describe a continuación:

- Obtención de datos de marea real de la estación de Tampico a través de Internet del marzo 2004 a marzo del 2005 y vientos del SMN de marzo a diciembre de 2004
- Presentación de un Modelo Neuronal con dos capas, alimentación hacia delante y algoritmo de retropropagación (neurona tipo feedforward). Para mostrar el funcionamiento del algoritmo de entrenamiento se presenta un pequeño ejemplo de entrenamiento.
- Entrenamiento de la red neuronal con datos de la estación de Tampico para predicción de marea astronómica, comparando los resultados con el método de predicción de mareas con componentes armónicos.
- Predicción de la marea residual de la estación de Tampico (marea registrada menos la marea astronómica) y comparación de los resultados.
- Presentación de un Modelo Neuronal tipo ADALINE (Estructura y algoritmo de entrenamiento) con un ejemplo del algoritmo de entrenamiento.
- Entrenamiento de la red neuronal tipo ADALINE para predicción de marea astronómica y comparación de los resultados.
- Predicción de la marea residual con la red neuronal tipo ADALINE y comparación de los resultados.
- Entrenamiento de la red neuronal tipo ADALINE para predicción de la marea real (astronómica + meteorológica) ingresando como datos de entrada la marea astronómica, la marea meteorológica o residual, datos de viento y datos de presión registrados en la estación meteorológica de Tampico.
- Comparación entre la predicción con redes neuronales y la predicción con componentes armónicos para la marea registrada en el mareógrafo de Tampico.
- Finalmente se hace un ejemplo práctico tomando los datos de la estación de Tampico y llevando a cabo la predicción para el siguiente día. Transcurridas 24 h se obtienen los datos de la estación mareográfica y se comparan con la predicción, nuevamente se hace la predicción de las siguientes 24 h y al día siguiente se comparan los resultados.

5.3 Datos

Los datos de elevaciones de la superficie libre del mar para el entrenamiento de las redes neuronales se obtuvieron del mareógrafo acústico con tubo de sondeo mencionado en el apartado **¡Error! No se encuentra el origen de la referencia.**, instalado en el Puerto de Tampico en el Estado de Tamaulipas. Este mareógrafo, que se encuentra operando desde el 24 de marzo del 2004, envía datos en tiempo real vía satélite que se pueden consultar en la dirección <http://lighthouse.tamucc.edu/gc/128>. Los datos de viento y presión barométrica

fueron provistos por el Servicio Meteorológico Nacional Mexicano (SMN) y se pueden consultar en la pagina (<http://smn.cna.gob.mx/productos/emas/paginas/altamira.html>).

Generalmente, la predicción de mareas se realiza con el método de componentes armónicos, sin tomar en cuenta la marea generada por los fenómenos meteorológico, en algunos casos esto es más que suficiente ya que la amplitud de marea debida a la atracción de los cuerpos celestes en comparación con la marea producida por perturbaciones meteorológicas es muy superior. Sin embargo en la Figura 5-3 se presentan los datos de la marea registrada en la estación de Tampico y la predicción de marea astronómica con componentes armónicos donde se puede observar una importante y clara diferencia entre una y otra. En el panel (A) se muestra la marea real registrada en la estación de Tampico (azul) y la predicción astronómica (verde), en el panel (B) se muestra la marea meteorológica que es la diferencia entre la marea real y la marea astronómica (residual), en el panel (C) y panel (D) se muestra el detalle 1 y 2 (del panel A), respectivamente. En el panel (C) se puede observar que el residual es despreciable, es decir que la marea real se puede describir simplemente con la marea astronómica, sin embargo en el panel D se observa una clara diferencia entre la marea registrada y la predicción con componentes armónicos esto debido probablemente a un fenómeno meteorológico que produjo una considerable sobrelevación del nivel del mar.

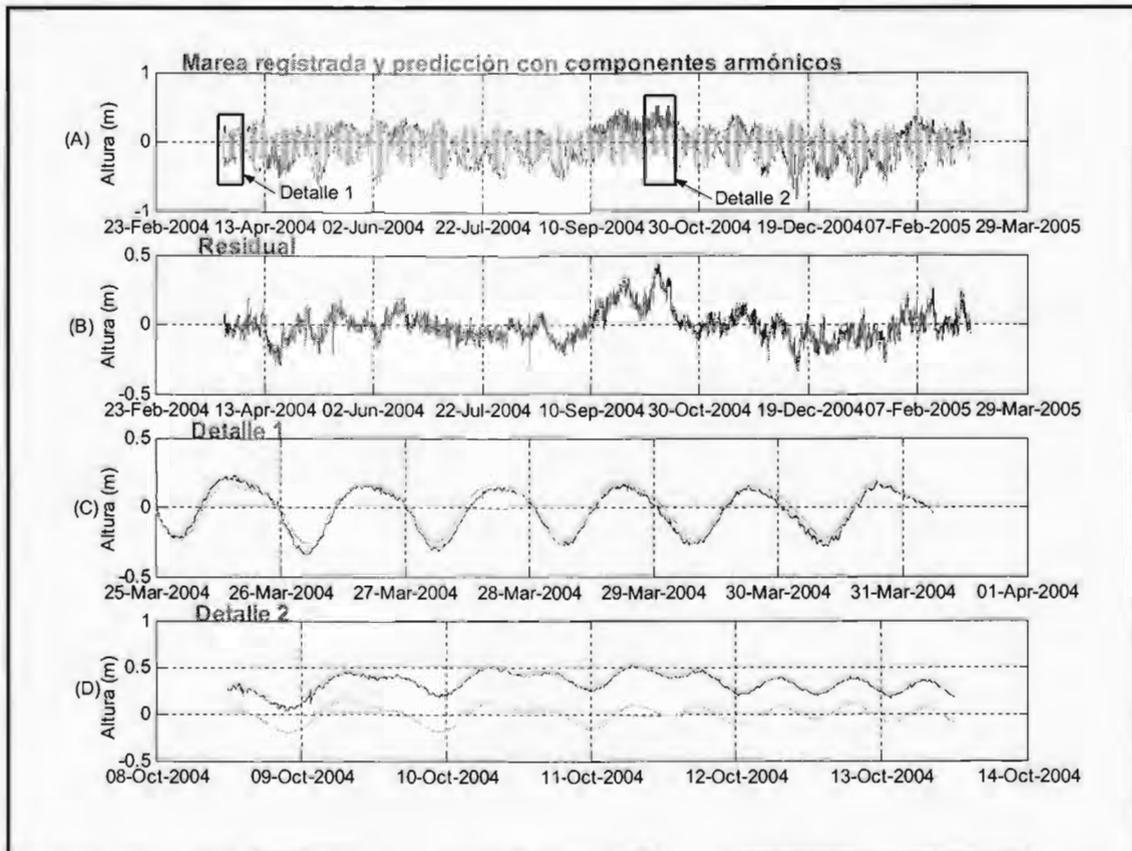


Figura 5-3 Comparación entre la marea registrada (azul) y la predicción de marea astronómica con componentes armónicos (verde), residual y detalles de la comparación de la marea y la marea astronómica

En la Figura 5-4 se presentan los datos de presión atmosférica y vientos para el mismo periodo, con la intención de relacionar el cambio en el aumento o disminución de la marea, con la presión o la intensidad de los vientos.

En el panel (A) de la Figura 5-4 se muestra nuevamente el residual de la marea, en el panel (B) se muestra la diferencia entre la presión normal de 1013 mb y la presión observada, en el panel (C) se muestra la componente del viento en la dirección Este-Oeste que corresponde a la componente **X**, (positivos = Este; negativos = Oeste), y finalmente en el panel inferior (D) se muestra la componente del viento en la dirección Norte-Sur que corresponde a la componente **Y**, (positivos = Norte; negativos = Sur).

Se puede apreciar, que donde hay un aumento considerable del nivel de marea, no existe un cambio en la presión y el viento significativo por lo que, *a priori*, parece no haber una clara correlación entre dichos procesos para este caso particular. Específicamente la sobrelevación del nivel de mar que se presenta entre el 10 y 30 de septiembre, no parece estar directamente relacionada con algún evento local de viento o presión. Por lo que se asume que la sobrelevación del nivel del mar está provocada por un evento remoto no registrado por la estación meteorológica de Tampico. Note que en la Figura 5-4 la componente de mayor magnitud de viento es del Este y en menor proporción del Norte y la resultante de estas dos componentes es del Noreste.

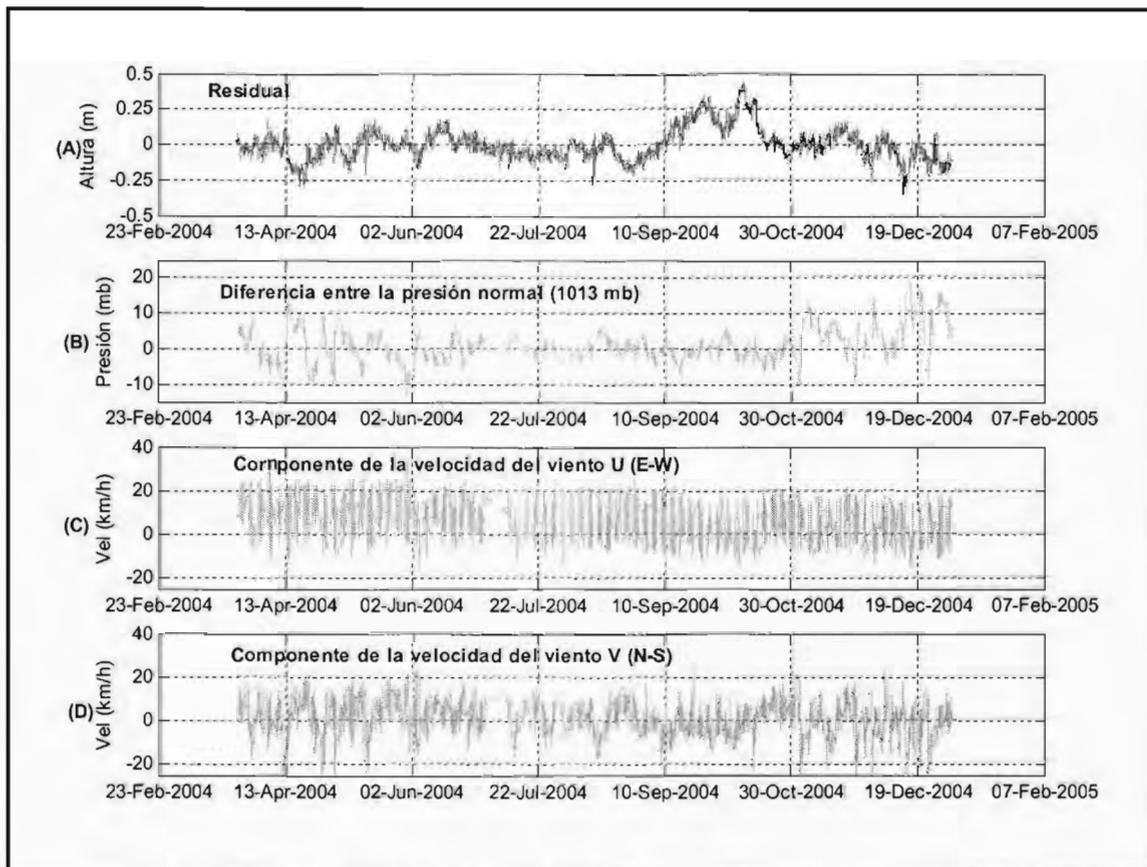


Figura 5-4 Variación de la presión y viento

5.4 Red Neuronal con multicapas con alimentación hacia delante (feedforward) y algoritmo de retropropagación (backpropagation)

En este punto se presentan las características de la neurona a utilizar, número de capas, funciones de transferencia y algoritmo de entrenamiento, también se presenta un pequeño ejemplo del algoritmo de entrenamiento.

5.4.1 Arquitectura Red Neuronal Multicapa

Una de las limitaciones que tenían las primeras neuronas (perceptrón) es que sólo podían clasificar cosas u objetos o propiedades si estos tenían una frontera lineal bien establecida; pero si la frontera no era lineal este tipo de arquitectura ya no servía para clasificar. Para solucionar este problema surgió la neurona con multicapas como la mostrada en la Figura 5-5 donde por facilidad sólo se muestran 3 capas, la salida de la primera capa es la entrada de la segunda y la salida de la segunda capa es la entrada de la tercer capa. Cada capa puede tener diferente número de neuronas y cada neurona diferente función de transferencia. La simbología de la numeración se muestra a continuación.

p_1	dato de entrada 1
\mathbf{p}	vector de datos de entrada
$w_{1,S_1,N}$	peso en la capa 1, número de neuronas (S) en la capa 1, número de pesos (N)
\mathbf{w}_1	matriz de pesos en la capa 1
b_{1,S_1}	sesgo (o bias) en la capa 1 para cada neurona (S) de la capa 1
\mathbf{b}_1	vector de sesgo de la capa 1
$n_{1,1}$	producto punto en la capa 1 de la neurona 1 $w_{1,1,1}p_1 + w_{1,1,2}p_2 + \dots + w_{1,1,S_1}p_N$ más sesgo b_{1,S_1}
$\mathbf{n}_1 = \mathbf{w}_1\mathbf{p} + \mathbf{b}_1$	vector de entradas para las funciones de transferencia en la capa 1
\mathbf{f}_1	vector de funciones de transferencia en la capa 1

Además de que este tipo de arquitectura sirve para clasificar, también se usa para aproximar funciones y filtrar datos. En la parte superior de la Figura 5-5 se muestra la representación de esta red neuronal, y debido a su configuración se intuye que este tipo de representación se complica para un número de neuronas mayor que 3. Para resolver este problema existe una representación en forma matricial que es más compacta y permite representar cualquier número de neuronas (ver parte inferior de la Figura 5-5).

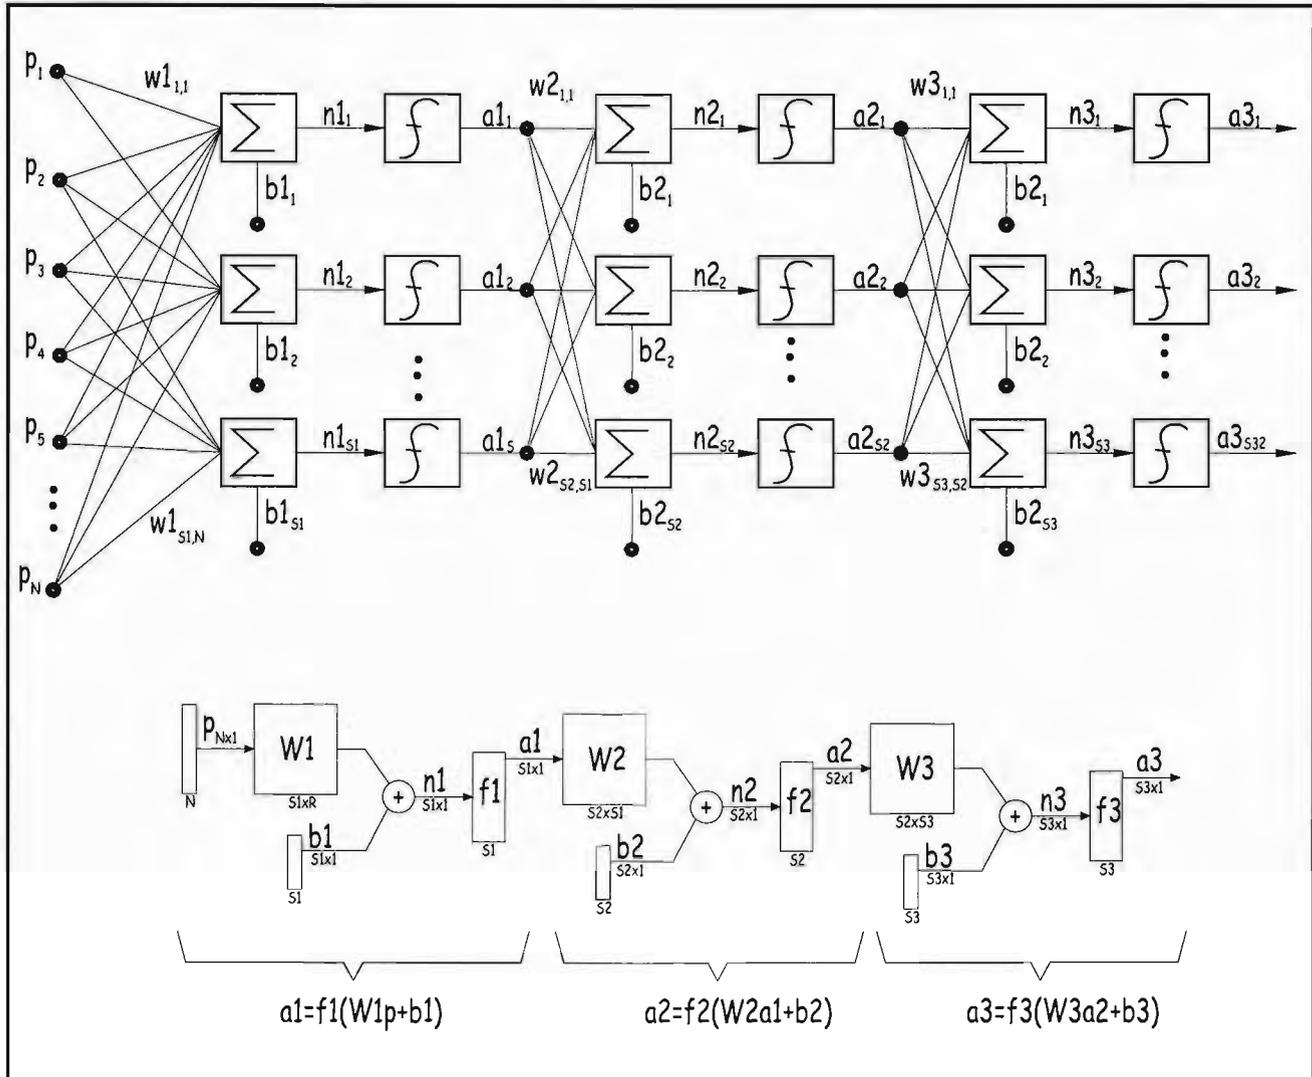


Figura 5-5 Arquitectura Red Neuronal con multicapas

La arquitectura más utilizada para aproximar funciones y filtrar datos es una red neuronal de multicapas como la mostrada en la Figura 5-6. Esta arquitectura de red neuronal será usada como ejemplo para mostrar el funcionamiento del algoritmo de entrenamiento y posteriormente será usada para la predicción de mareas.

Esta red neuronal consta de una capa intermedia con función de transferencia de tipo sigmog, y una capa de salida con función de transferencia de tipo lineal. Los parámetros que se pueden variar en este tipo de neurona son: número de datos de entrada, número de neuronas en la capa intermedia, número de neuronas en la capa de salida y por último cantidad de ciclos de entrenamiento. Un ciclo de entrenamiento corresponde a la entrada de datos a la red, el resultado de la salida, la obtención del error entre la salida de la red y el valor real y por último la actualización de los pesos. El procedimiento de entrenamiento se puede resumir como sigue:

El primer paso es propagar los datos de entrada a través de la red, mediante las siguientes ecuaciones:

Vector de entrada inicial

$$\mathbf{a}_0 = \mathbf{p} \quad (6)$$

Vector de salida en la capa m+1

$$\mathbf{a}_{m+1} = \mathbf{f}_{m+1}((\mathbf{w}_{m+1})(\mathbf{a}_m) + \mathbf{b}_{m+1}) \quad (7)$$

Vector de resultados de la red

$$\mathbf{a} = \mathbf{a}_M \quad (8)$$

Para $m = 0, 1, \dots, M-1$ (Layer o capa)

El siguiente paso es propagar el error hacia atrás, con el coeficiente de sensibilidad dado por las ecuaciones (9) y (10)

$$\mathbf{S}_m = \dot{\mathbf{F}}_m(\mathbf{n}_m)(\mathbf{w}_{m+1})' \mathbf{S}_{m+1} \quad (9)$$

para $m = 0, 1, \dots, M-1$ (Layer o capa), y

$$\mathbf{S}_M = -2 \dot{\mathbf{F}}_M(\mathbf{n}_M)(T - \mathbf{a}) \quad (10)$$

Para $m=M$

Donde

$(\mathbf{w}_{m+1})'$ Es la matriz transpuesta de pesos en la capa m+1, para $m=M-1, \dots, 2, 1$

Las derivadas de las ecuaciones (9) y (10) esta dadas por

$$\dot{\mathbf{F}}_m(\mathbf{n}_m) = \begin{bmatrix} f'_m(n_{m,1}) & 0 & \dots & 0 \\ 0 & f'_m(n_{m,2}) & \dots & 0 \\ 0 & 0 & \dots & \dots \\ 0 & 0 & \dots & f'_m(n_{m,j}) \end{bmatrix} \quad (11)$$

$$\dot{f}_m(n_{m,j}) = \frac{\partial f_m(n_{m,j})}{\partial n_{m,j}} \quad (12)$$

Finalmente los pesos y sesgos son actualizados usando la aproximación del gradiente descendiente en el tiempo $k+1$

$$\mathbf{w}_m(k+1) = \mathbf{w}_m(k) - \alpha(\mathbf{S})(\mathbf{a}_{m-1}) \quad (13)$$

$$\mathbf{b}_m(k+1) = \mathbf{b}_m(k) - \alpha \mathbf{S}_m \quad (14)$$

Donde la letra en negrita representa a un vector o una matriz

M	número de capas en la red
m	número de la capa que va de 1 a M-1
α	coeficiente de aprendizaje mayor que 0 y menor que 1

Es importante mencionar que entre menor es el coeficiente de aprendizaje la precisión es mayor, pero el tiempo de cómputo se incrementa, por lo tanto se recomienda seleccionar un coeficiente de aprendizaje entre 0.10 y 0.50.

5.4.2 Ejemplo de algoritmo de entrenamiento

La red neuronal mostrada en la Figura 5-6 consta de una capa intermedia con función de transferencia logsig y una capa de salida con función de transferencia lineal (ecuaciones (15) y (16)); las derivadas de las funciones de transferencia están dadas por las ecuaciones (17) y (18), respectivamente.

$$f(\mathbf{n}) = \frac{1}{1+e^{-\mathbf{n}}} \equiv \mathbf{a} \quad (15) \quad \text{Función de transferencia log-sigmoid}$$

$$f(\mathbf{n}) \equiv \mathbf{a} \quad (16) \quad \text{Función de transferencia lineal}$$

En este caso de dos capas, se tiene entonces:

$$\frac{df_1}{dn_1} = \frac{d}{dn} \left(\frac{1}{1+e^{-n}} \right) = \frac{e^n}{(1+e^{-1})^2} = \left(1 - \frac{1}{1+e^{-n}} \right) \left(\frac{1}{1+e^{-n}} \right) = (1-a_1)(a_1) \quad (17)$$

$$\frac{df_2}{dn} = \frac{d}{dn}(n) = 1 \quad (18)$$

Los coeficientes de sensibilidad en este caso están dados por:

$$S_2 = -2(T - a) = -2(\text{error})$$

$$S_1 = \dot{F}_1(\mathbf{n}_1)(\mathbf{w}_2)' S_2$$

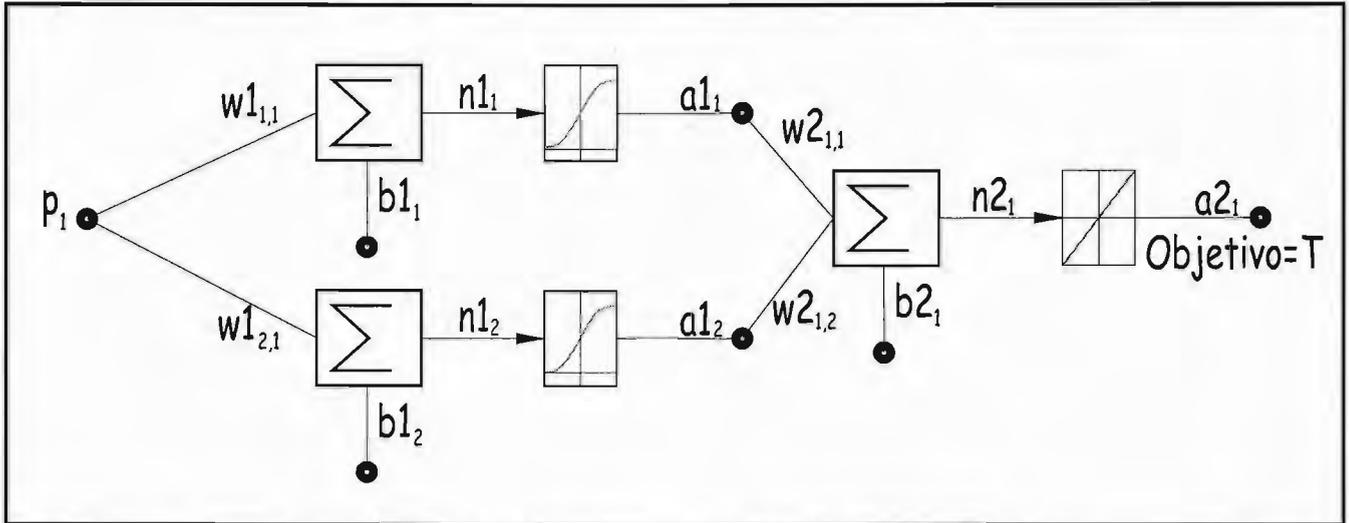


Figura 5-6 Arquitectura RNA multicapa con retropropagación

Los datos para el ejemplo se obtienen de la función (19) y se muestran en la Tabla 5-1,

$$g(p) = 1 + \sin\left(\frac{\pi}{4} p\right) \quad (19)$$

Tabla 5-1 Datos de entrada neurona multicapa

P	T
-2	0.000
-1.5	0.076
-1	0.293
-0.5	0.617
0	1.000
0.5	1.383
1	1.707
1.5	1.924
2	2.000

Paso (1)

Antes de iniciar es necesario asignarle valores a los pesos y sesgos los cuales pueden ser aleatorios, y para el ejemplo se consideran:

$$\mathbf{w}_1(0) = \begin{bmatrix} -0.27 \\ -0.41 \end{bmatrix}, \quad \mathbf{b}_1(0) = \begin{bmatrix} -0.48 \\ -0.13 \end{bmatrix} \quad \text{y} \quad \mathbf{w}_2(0) = [0.09 \quad -0.17], \quad \mathbf{b}_2(0) = [0.48]$$

Paso 2 propagar los datos a través de la red seleccionando como valor inicial de entrada por comodidad $p=1$, por lo tanto $a(0)=1$ y la salida de la primera capa es:

$$\mathbf{a}_1 = f(\mathbf{w}_1 \mathbf{a}(0) + \mathbf{b}_1) = \log sig \left(\begin{bmatrix} -0.27 \\ -0.41 \end{bmatrix} 1 + \begin{bmatrix} -0.48 \\ -0.13 \end{bmatrix} \right) = \log sig \left(\begin{bmatrix} -0.75 \\ -0.54 \end{bmatrix} \right) = \begin{bmatrix} \frac{1}{1 + e^{0.75}} \\ \frac{1}{1 + e^{0.54}} \end{bmatrix} = \begin{bmatrix} 0.321 \\ 0.368 \end{bmatrix}$$

La salida de la segunda capa es:

$$\mathbf{a}_2 = f_2(\mathbf{w}_2 \mathbf{a}_1 + \mathbf{b}_2) = \text{lineal} \left(\begin{bmatrix} 0.09 & -0.17 \end{bmatrix} \begin{bmatrix} 0.321 \\ 0.368 \end{bmatrix} + \begin{bmatrix} 0.48 \end{bmatrix} \right) = \begin{bmatrix} 0.446 \end{bmatrix}$$

Paso 3 se obtiene el error para $p=1$ y $T=1.707$

$$e = T - a = 1.707 - 0.446 = 1.261$$

Paso 3 cálculo de los coeficientes de sensibilidad, utilizando las derivadas correspondientes se obtiene:

$$S_2 = -2(T - a) = -2(1.261) = -2.522$$

$$\begin{aligned} \mathbf{S}_1 &= \dot{F}_1(\mathbf{n}_1)(\mathbf{w}_2)' \mathbf{S}_2 = \begin{bmatrix} (1 - a_{1,1})a_{1,1} & 0 \\ 0 & (1 - a_{1,2})a_{1,2} \end{bmatrix} \begin{bmatrix} 0.09 \\ -0.17 \end{bmatrix} \begin{bmatrix} -2.522 \end{bmatrix} \\ &= \begin{bmatrix} (1 - 0.321)(0.321) & 0 \\ 0 & (1 - 0.368)(0.368) \end{bmatrix} \begin{bmatrix} 0.09 \\ -0.17 \end{bmatrix} \begin{bmatrix} -2.522 \end{bmatrix} = \begin{bmatrix} -0.0495 \\ 0.0997 \end{bmatrix} \end{aligned}$$

Paso 4 El paso final del algoritmo es actualizar los pesos y sesgos; por simplicidad se selecciona $\alpha = 0.1$

$$\mathbf{w}_2(1) = \mathbf{w}_2(0) - \alpha S_2(\mathbf{a}_1)' = \begin{bmatrix} 0.09 & -0.17 \end{bmatrix} - 0.1 \begin{bmatrix} -2.522 \end{bmatrix} \begin{bmatrix} 0.321 & 0.368 \end{bmatrix} = \begin{bmatrix} 0.171 & -0.0772 \end{bmatrix}$$

$$\mathbf{b}_2(1) = \mathbf{b}_2(0) - \alpha S_2 = \begin{bmatrix} 0.48 \end{bmatrix} - 0.1 \begin{bmatrix} -2.522 \end{bmatrix} = \begin{bmatrix} 0.732 \end{bmatrix}$$

$$\mathbf{w}_1(1) = \mathbf{w}_1(0) - \alpha S_1(\mathbf{a}_0)' = \begin{bmatrix} -0.27 \\ -0.41 \end{bmatrix} - 0.1 \begin{bmatrix} -0.0495 \\ 0.0997 \end{bmatrix} \begin{bmatrix} 1 \end{bmatrix} = \begin{bmatrix} -0.265 \\ -0.420 \end{bmatrix}$$

$$\mathbf{b}_1(1) = \mathbf{b}_1(0) - \alpha S_1 = \begin{bmatrix} -0.48 \\ -0.13 \end{bmatrix} - 0.1 \begin{bmatrix} -0.0495 \\ 0.0997 \end{bmatrix} = \begin{bmatrix} -0.475 \\ -0.140 \end{bmatrix}$$

Esto completa el primer ciclo de entrenamiento o la primera iteración del algoritmo de retropropagación. El siguiente paso es seleccionar otra entrada y realizar el mismo

procedimiento hasta que la diferencia entre los pesos sea mínima o la respuesta de la red y el valor real sean similares dentro de un nivel aceptable.

Para el problema de predicción de marea que no ocupa es necesario definir el valor del error que dependerá del número de entradas a la red, la cantidad de ciclos de entrenamiento y el número de horas a predecir. Sin embargo aún no se sabe si la red neuronal propuesta es capaz de predecir la marea real, por lo tanto para verificar el funcionamiento de la RNA se trabaja en primera instancia con la marea astronómica ya que ésta presenta un comportamiento más definido que la marea real y se supone es, en cierta medida más fácil de predecir.

5.4.3 Entrenamiento red neuronal multicapa

Con el fin de comparar resultados entre la predicción con RNA para marea astronómica, variando vectores de entrada y ciclos de entrenamiento, se seleccionó el periodo del 9 al 11 de octubre del 2004

La arquitectura de la red neuronal ocupada a diferencia de la RNA de la Figura 5-6 consta de 3 neuronas en la capa intermedia. El entrenamiento de la red neuronal se inicio con 24 datos de entrada (1 día) \mathbf{p}_{1-24} y 48 ciclos de entrenamiento (2 días) para lo cual es necesario de 3 días de registro \mathbf{p}_{1-72} . Siguiendo el procedimiento mencionado en el apartado 5.4.2 se tiene:

Paso 1, se crea la red neuronal especificando aleatoriamente los pesos y sesgos para las 3 neuronas de la capa 1 las dimensiones de la matriz de pesos y el vector de sesgos será por lo tanto $\mathbf{w}_1[3 \times 24]$ ($S_1 \times R$) y $\mathbf{b}_1[3 \times 1]$ ($S_1 \times 1$), una neurona en la capa 2 para la cual el vector de pesos y sesgos será de dimensión $\mathbf{w}_2[1 \times 3]$ ($S_2 \times S_1$) y $\mathbf{b}_2[1 \times 1]$ ($S_2 \times 1$) (ver Figura 5-5), funciones de transferencia logsig y lineal para la capa intermedia y salida respectivamente.

Paso 2, se propagan los datos a través de la red ingresando las primeras 24 horas de los 3 días del registro \mathbf{p}_{1-24} y se espera que la salida de la red neuronal sea la elevación de la marea astronómica en la hora 25 $T = p_{25}$.

$$\mathbf{a}_1 = f(\mathbf{w}_1 \mathbf{p}_{1-24} + \mathbf{b}_1) = \text{logsig}(\mathbf{w}_1 \mathbf{p}_{1-24} + \mathbf{b}_1)$$

$$\mathbf{a}_2 = f_2(\mathbf{w}_2 \mathbf{a}_1 + \mathbf{b}_2) = \text{lineal}(\mathbf{w}_2 \mathbf{a}_1 + \mathbf{b}_2) = (\mathbf{w}_2 \mathbf{a}_1 + \mathbf{b}_2)$$

Paso 3, se obtiene el error

$$e = T - a = p_{25} - a_2$$

Paso 4 se obtienen los coeficientes de sensibilidad o retropropagación

$$\mathbf{S}_2 = -2(T - a) = -2(p_{25} - a_2)$$

$$\mathbf{S}_1 = \dot{\mathbf{F}}_1(\mathbf{n}_1)(\mathbf{w}_2)' \mathbf{S}_2 = \begin{bmatrix} (1 - a_{1,1})(a_{1,1}) & 0 & 0 \\ 0 & (1 - a_{1,2})(a_{1,2}) & 0 \\ 0 & 0 & (1 - a_{1,3})(a_{1,3}) \end{bmatrix} \mathbf{w}_2' \mathbf{S}_2$$

Paso 4, los pesos y sesgos son actualizados se recomienda $\alpha = 0.1 - 0.5$

$$\mathbf{w}_2(1) = \mathbf{w}_2(0) - \alpha S_2(\mathbf{a}_1)'$$

$$\mathbf{b}_2(1) = \mathbf{b}_2(0) - \alpha S_2$$

$$\mathbf{w}_1(1) = \mathbf{w}_1(0) - \alpha S_1(\mathbf{a}_0)'$$

$$\mathbf{b}_1(1) = \mathbf{b}_1(0) - \alpha S_1$$

En la siguiente iteración los datos de entrada van de la hora 2 a la 25 \mathbf{p}_{2-25} y el valor que se espera de la RNA es el valor de la marea para la hora 26 $T=p_{26}$, con los pasos del 1 al 6 nuevamente los pesos se actualizan y se ingresa un nuevo vector de datos, el entrenamiento termina al final de los tres días de registro.

Para conocer la mejor combinación de datos de entrada y tiempo de entrenamiento, se fue variando la cantidad de días de entrenamiento desde 3 días de registro hasta 50 aumentando en 24 horas, manteniendo fijo el vector de entrada, de esta manera se obtuvo el error medio cuadrático para estos tres días (9 al 11 de octubre) con las combinaciones (1-3,1-4,...1-50). Posteriormente se aumentó el número de los datos de entrada en 24 y se obtuvieron las combinaciones (2-4,2-5,...2-50) así sucesivamente hasta 5 días para el vector de datos de entrada. los resultados se muestran gráficamente en la Figura 5-7 donde se puede observar que a partir de 20 días de ciclos de entrenamiento los resultados son similares para los vectores de pesos 2,3,4 y 5 días y para un día del vector de pesos el error está muy alejado de todos los demás por lo cual queda descartado.

Cabe mencionar que el tiempo de registro debe considerar las horas de los datos de entrada más el tiempo de entrenamiento que en este caso se consideró de 2 días, así por ejemplo para la combinación (5-7) que corresponde a 5 días para el vector de entradas y 7 días de registro, con dos días para los ciclos de entrenamiento, no existen valores para un registro menor que 7 días, lo que se ve reflejado en una línea horizontal al inicio de la grafica para cada combinación.

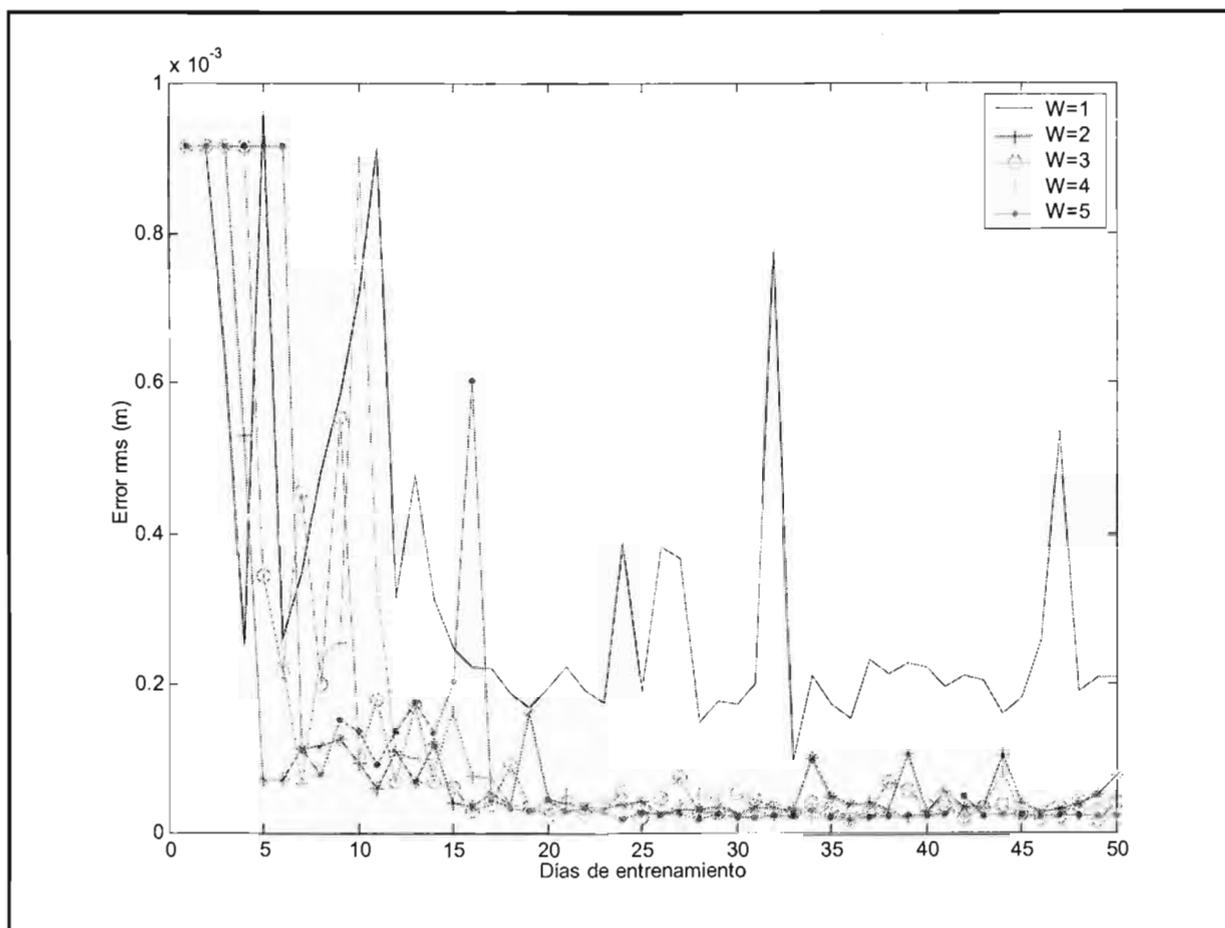


Figura 5-7 Comparación entre diferentes combinaciones del vector de entrada ("pesos") y la cantidad de ciclos de entrenamiento, (error en m.)

5.4.4 Predicción de la marea astronómica

De acuerdo a los resultados obtenidos en el inciso 5.4.3 la combinación de 25 días de registro y 3 días para el vector de pesos presenta los errores más bajos sin ocupar tanto recurso computacional.

Con la combinación de 3 días para el vector de entrada y 25 días de registro que corresponden a 22 días de entrenamiento, se obtuvo la predicción de marea astronómica con la red neuronal multicapa. Los resultados de la predicción se presentan en la Figura 5-8, donde se puede observar un buen ajuste entre la predicción con componentes armónicos y la predicción con redes neuronales para 24 horas.

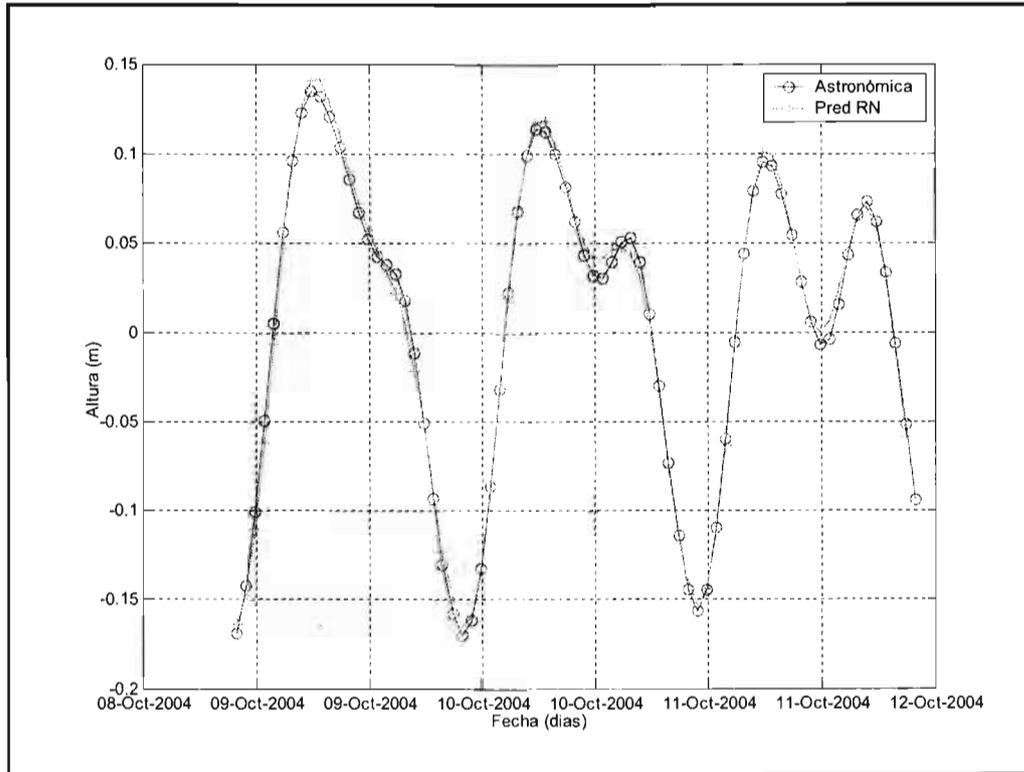


Figura 5-8 Predicción de marea astronómica con red neuronal multicapa

5.4.5 Predicción del residual

Una manera de obtener la marea real o total en el sitio (marea astronómica + marea meteorológica) es, por un lado, obtener la predicción de la marea astronómica con componentes armónicos y, por otro lado, obtener la predicción del residual (marea meteorológica) con RNA, y de esta manera se puede predecir la marea total en cualquier sitio.

Por lo tanto, si la red neuronal propuesta anteriormente es capaz de estimar adecuadamente la marea residual se tendrá en consecuencia la capacidad de predecir adecuadamente la marea total.

Para la predicción de la marea residual se llevó a cabo el mismo procedimiento descrito anteriormente para la predicción de marea astronómica con la combinación 3-25 (vector de pesos y ciclos de entrenamiento) con el registro del residual de la estación de Tampico.

Los resultados de la predicción del residual se presentan en forma gráfica en la Figura 5-9 donde se puede observar que el desempeño no es satisfactorio y está muy alejado del valor real. Por lo tanto se buscó otra arquitectura ya que en esta misma figura se observa que aunque el residual tenga una tendencia a subir la predicción no tiene la misma tendencia por lo cual se descarta este tipo de entrenamiento.

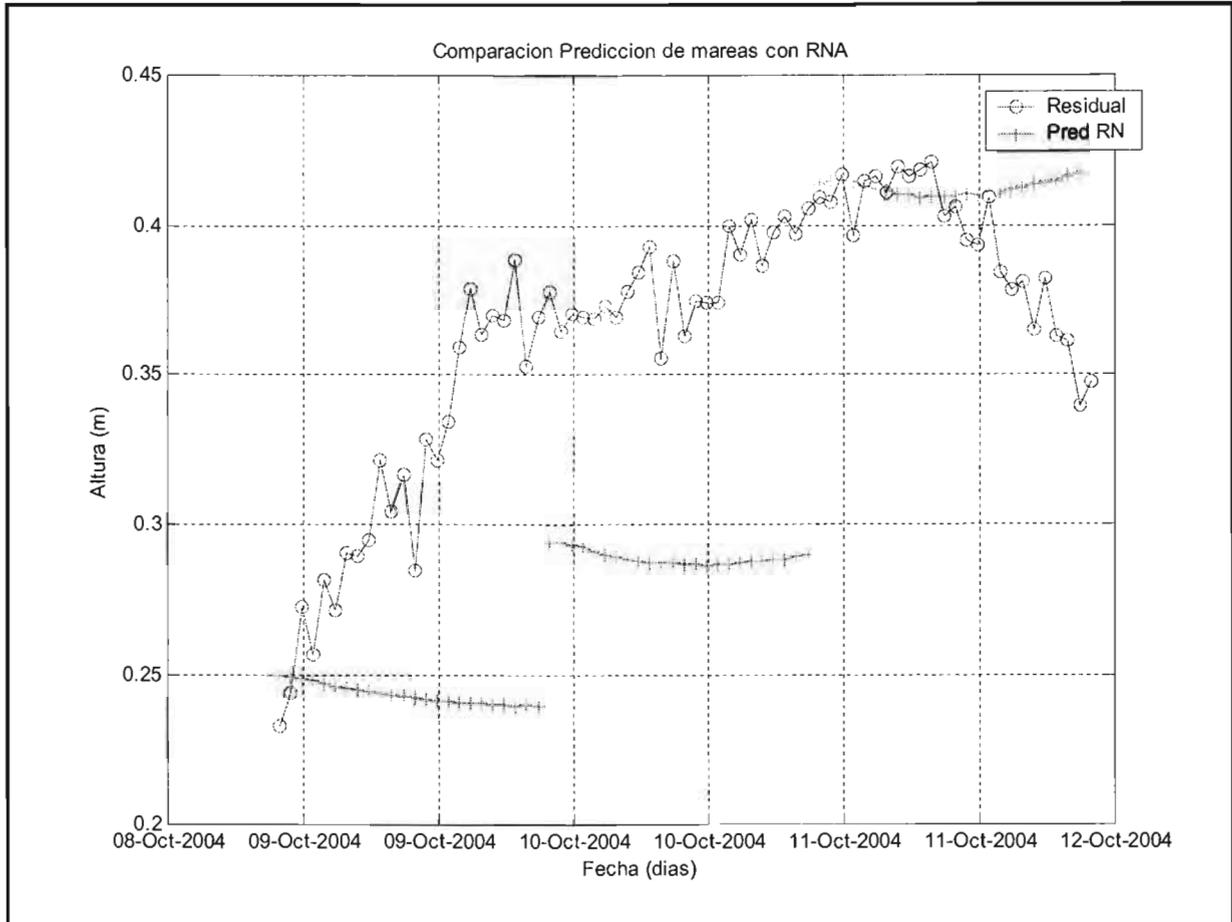


Figura 5-9 Predicción del residual con la red neuronal de multicapa

5.5 Red Neuronal ADALINE

La neurona tipo ADALINE tiene una función de transferencia lineal. Esta clase de red neuronal es adecuada para filtrar datos, ajustar datos históricos a una función matemática y realizar cierto tipo de predicciones.

5.5.1 Arquitectura

La arquitectura de la red neuronal ADALINE consiste de una sola capa de neuronas con función de transferencia lineal como la mostrada en la Figura 5-10, por esta razón el índice que representa la capa es omitido.

Con esta arquitectura de red neuronal se hace la predicción de la marea astronómica y posteriormente la marea meteorológica o residual.

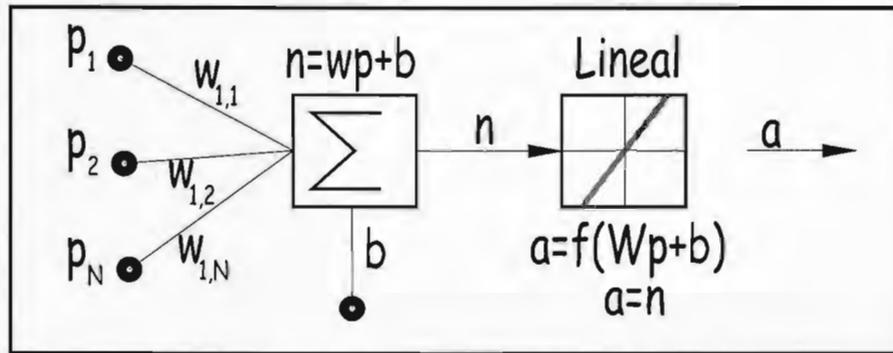


Figura 5-10 Arquitectura red neuronal ADALINE

El algoritmo de entrenamiento para la RNA ADALINE consiste simplemente en la actualización de los “pesos” y sesgos después de obtener el error, dado por la diferencia de la salida de la red y el valor real. La actualización de los “pesos” y sesgos esta dado por las ecuaciones (20) y (21) las cuales son derivadas del método del gradiente descendiente y el método de mínimos cuadrados:

$$\mathbf{w}(k+1) = \mathbf{w}(k) + 2\alpha e(k)\mathbf{p}(k) \quad (20)$$

$$\mathbf{b}(k+1) = \mathbf{b}(k) + 2\alpha e(k) \quad (21)$$

donde:

- $\mathbf{w}(k+1)$ vector de pesos en el tiempo $k+1$
- $\mathbf{w}(k)$ vector de pesos en el tiempo k
- $e(k)$ es el error calculado en el tiempo k
- $\mathbf{p}(k)$ vector de datos en el tiempo k
- α coeficiente de aprendizaje

El valor de α al igual que la red de multicapas puede tomar valores entre 0.1 y 0.9

5.5.2 Ejemplo de algoritmo de entrenamiento

A continuación se presenta un pequeño ejemplo con la finalidad de entender mejor el algoritmo de entrenamiento.

El valor de α se fija en 0.2, los “pesos” iniciales se consideran cero y

$$\left\{ p_1 = \begin{bmatrix} 1 \\ -1 \\ -1 \end{bmatrix}, T_1 = [-1] \right\}, \left\{ p_2 = \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix}, T_2 = [1] \right\}$$

Para el primer ciclo de entrenamiento se tiene:

$$\mathbf{a}(0) = \mathbf{w}(0)\mathbf{p}(0) + \mathbf{b}(0) = \mathbf{w}(0)\mathbf{p}_1 + \mathbf{b}(0) = \begin{bmatrix} 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ -1 \\ -1 \end{bmatrix} + 0 = 0,$$

El error es

$$e(0) = T(0) - \mathbf{a}(0) = T_1 - \mathbf{a}(0) = -1 - 0 = -1,$$

Los nuevos “pesos” y “bias” son:

$$\mathbf{w}(1) = \mathbf{w}(0) + 2\alpha e(0)\mathbf{p}'(0) = \begin{bmatrix} 0 & 0 & 0 \end{bmatrix} + (2)(0.2)(-1) \begin{bmatrix} 1 & -1 & -1 \end{bmatrix} = \begin{bmatrix} -0.4 & 0.4 & 0.4 \end{bmatrix}$$

$$\mathbf{b}(1) = \mathbf{b}(0) + 2\alpha e(0) = 0 + (2)(0.2)(-1) = -0.4$$

El siguiente ciclo de entrenamiento esta dado por:

$$\mathbf{a}(1) = \mathbf{w}(1)\mathbf{p}(1) + \mathbf{b}(1) = \mathbf{w}(1)\mathbf{p}_2 + \mathbf{b}(1) = \begin{bmatrix} -0.4 & 0.4 & 0.4 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix} + 0.4 = 0,$$

$$e(1) = T(1) - \mathbf{a}(1) = T_2 - \mathbf{a}(1) = 1 - 0 = 1,$$

$$\mathbf{w}(2) = \mathbf{w}(1) + 2\alpha e(1)\mathbf{p}'(1) = \begin{bmatrix} -0.4 & 0.4 & 0.4 \end{bmatrix} + (2)(0.2)(1) \begin{bmatrix} 1 & 1 & -1 \end{bmatrix} = \begin{bmatrix} 0 & .8 & 0 \end{bmatrix}$$

$$\mathbf{b}(2) = \mathbf{b}(1) + 2\alpha e(1) = -0.4 + (2)(0.2)(1) = 0$$

Realizando mas iteraciones se puede observar que los “pesos” y sesgo tienden a:

$$\mathbf{w} = \begin{bmatrix} 0 & 1 & 0 \end{bmatrix}, \mathbf{b} = 0$$

Haciendo un ejercicio para los dos valores de entrada anteriores con estos valores de peso y sesgo, se tiene que los resultados son correctos

$$\mathbf{a}_1 = \mathbf{w}\mathbf{p}_1 + \mathbf{b} = \begin{bmatrix} 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ -1 \\ -1 \end{bmatrix} + 0 = -1,$$

$$\mathbf{a}_2 = \mathbf{w}\mathbf{p}_2 + \mathbf{b} = \begin{bmatrix} 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix} + 0 = 1,$$

5.5.3 Entrenamiento

Una vez seleccionada la red neuronal, es necesario definir la cantidad de datos de entrada, y la cantidad de ciclos de entrenamiento. El procedimiento para encontrar la mejor combinación es similar a la red con multicapas. Se fija la cantidad de datos de entrada y se va aumentando el tiempo de entrenamiento, en este caso hasta 20 días, posteriormente se aumenta la cantidad de datos del vector de entrada y se incrementan nuevamente los ciclos de entrenamiento (ver Tabla 5-2).

Nuevamente para el entrenamiento de la red neuronal, el tiempo de registro debe considerar las horas de los datos de entrada más el tiempo de entrenamiento que en este caso se consideró igual al vector de entrada, así por ejemplo para la combinación (3-6), el número 3 corresponde a los días del vector de entrada y 6 a los días de registro, en este caso el ciclo de entrenamiento es de 3 días. Por lo anterior en la Tabla 5-2 donde se muestra el error para diferentes combinaciones, no existen datos en la parte inferior izquierda. Estos mismos datos se encuentran representados en la Figura 5-11, la ausencia de datos al inicio de algunas combinaciones es por la misma razón mencionada anteriormente.

En la Figura 5-11 se muestra el error entre la predicción con RNA y la marea astronómica para diferentes combinaciones. Se puede apreciar una tendencia decreciente del error para una mayor cantidad de datos de entrenamiento y número de elementos en el vector de entrada, sin embargo a partir de 12 días de entrenamiento no existe mucha diferencia entre el error de una combinación y otra, en cambio el tiempo de computadora si aumenta considerablemente (de un minuto para la combinación 4-12, a 30 minutos para la combinación de 7-17). Por lo tanto la combinación 4-12 parece la más adecuada ya que corresponde a la combinación para la cual el error se encuentra entre los más bajos y el tiempo de cómputo no es significativo.

Tabla 5-2 Valores de error medio cuadrático entre la marea astronómica y la predicción con RNA

Pesos(días)	DIAS DE ENTRENAMIENTO (Marea Astronomica)																				minimo
	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20		
1	0.03	0.007	0.011	0.015	0.021	0.026	0.031	0.033	0.032	0.03	0.026	0.023	0.02	0.018	0.017	0.017	0.017	0.017	0.016	0.007	
2			0.003	0.002	0.004	0.007	0.01	0.01	0.007	0.01	0.012	0.013	0.013	0.014	0.013	0.014	0.014	0.014	0.014	0.002	
3					9E-04	3E-04	4E-04	5E-04	6E-04	8E-04	0.001	0.001	0.002	0.002	0.002	0.001	7E-04	4E-04	4E-04	3E-04	
4							4E-04	4E-04	4E-04	2E-04	1E-04	1E-04	1E-04	2E-04	2E-04	3E-04	3E-04	3E-04	2E-04	1E-04	
5									7E-04	3E-04	2E-04	2E-04	2E-04	2E-04							
6											4E-04	3E-04	2E-04	3E-04	3E-04	2E-04	2E-04	2E-04	2E-04	2E-04	
7												5E-04	2E-04	2E-04	2E-04	1E-04	1E-04	1E-04	1E-04	1E-04	
8																0.001	2E-04	1E-04	9E-05	9E-05	
9																		0.001	1E-04	1E-04	
10																			4E-04	4E-04	

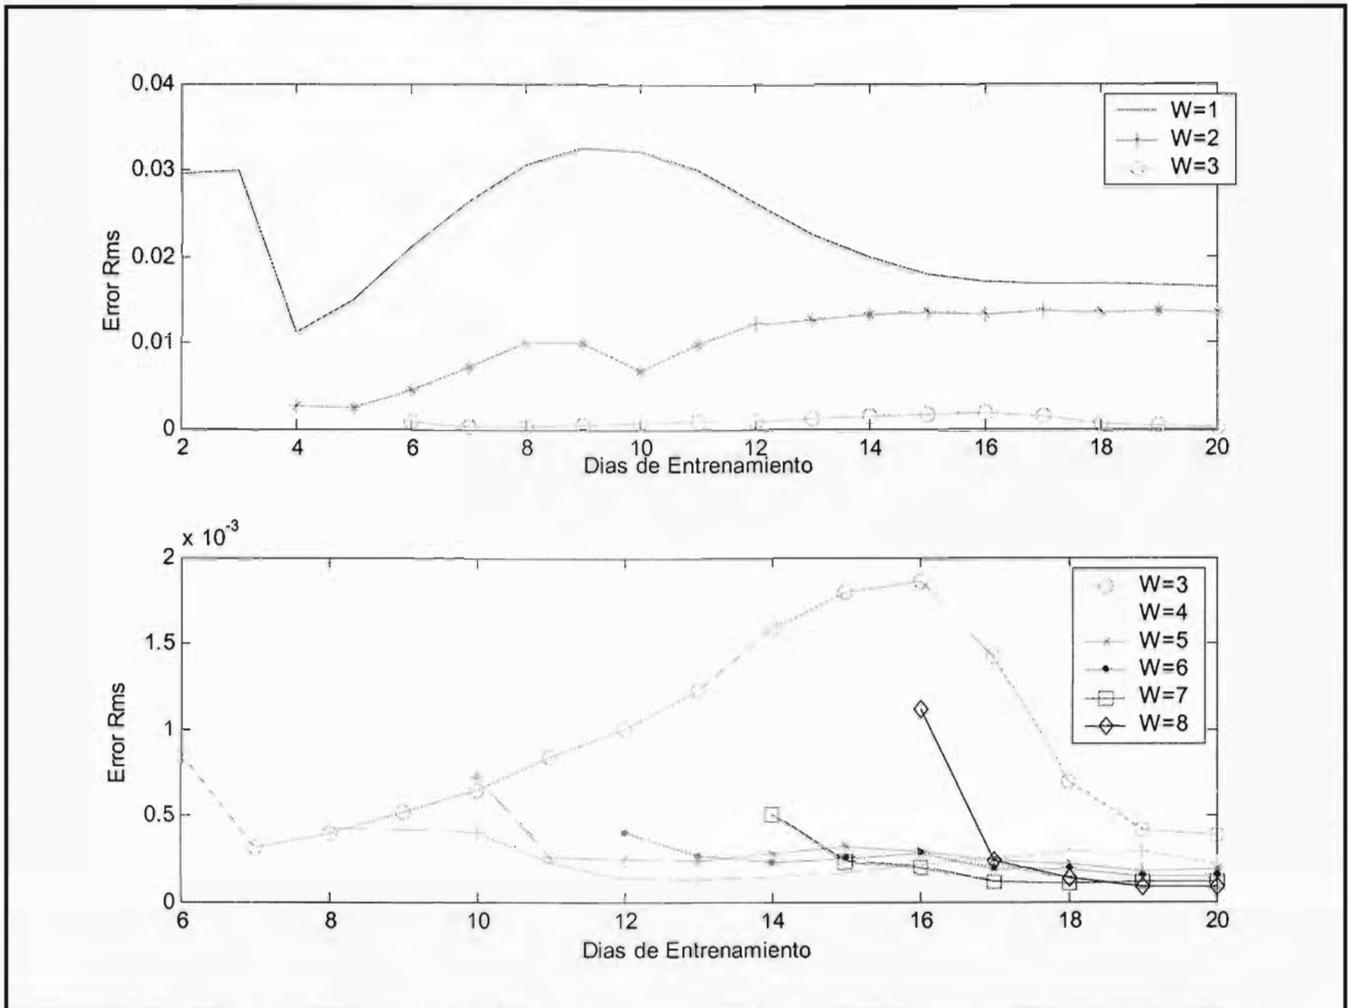


Figura 5-11 Comparación de error medio cuadrático con diferentes combinaciones

5.5.4 Predicción de la marea astronómica

Con la combinación de 4 días para el vector de entrada y 12 días de registro que corresponden a 8 días de entrenamiento, se obtuvo la predicción de marea astronómica con la red neuronal propuesta. Los resultados de la predicción se presentan en la Figura 5-12, donde se puede observar un buen ajuste entre la predicción con componentes armónicos (círculos) y la predicción con RNA (cruces), también se puede ver que existe un mejor ajuste con esta red que con la red neuronal multicapa, presentada anteriormente.

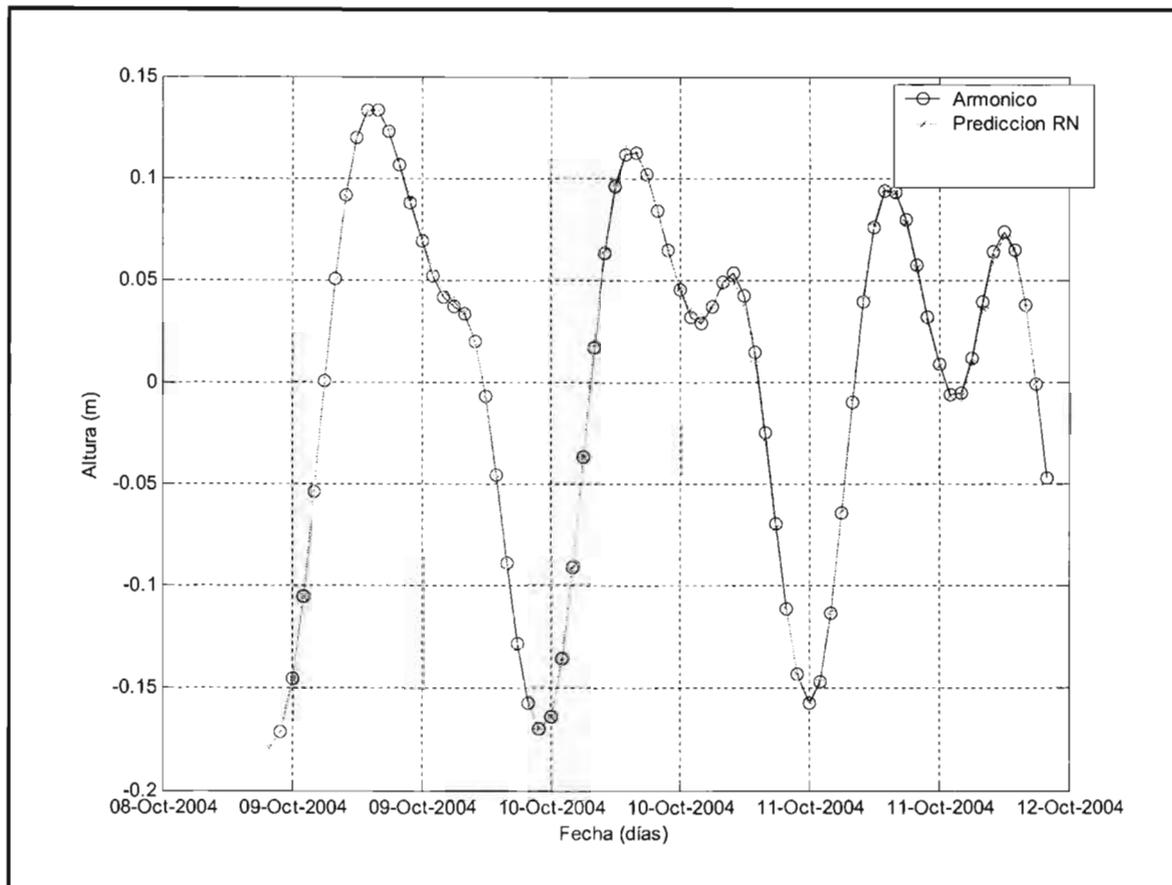


Figura 5-12 Predicción de marea astronómica con $W=4$ días vector de pesos y $P=12$ elementos el vector de entrenamiento para 24 horas de predicción

5.5.5 Predicción del residual

Una vez probado que la red neuronal tiene un buen desempeño en la predicción de la marea astronómica, se entrenó la misma para predecir el residual (marea meteorológica).

El procedimiento de entrenamiento fue el mismo que se siguió anteriormente y el resultado de la predicción se presenta en la Figura 5-13.

Sin embargo, se observa de los resultados mostrados en la Figura 5-13, donde está representado el residual (círculos) y la predicción con la RNA (asteriscos), que no se tiene un buen ajuste, ya que el error en este caso es inaceptable (más del 100%). Para un mejor desempeño del modelo de predicción es necesario considerar otra variable, como puede ser viento o presión, o buscar otra arquitectura o método de entrenamiento más adecuado.

5.6 Predicción de la marea real (astronómica + residual)

Debido a que ninguna de las dos arquitecturas de red neuronal presentadas en los apartados 5.4 y 5.5 funciona adecuadamente en la estimación del residual, se decidió cambiar la forma de entrenamiento de la red neuronal ADALINE, ingresando separadamente datos de marea astronómica, residual, viento y presión para obtener la marea real. Al igual que antes se llevó a cabo una variación entre diferentes días de entrenamiento (de 20 a 100) y diferentes días para la matriz de pesos (de 1 a 10 días) para obtener la combinación más favorable para la predicción. Los resultados se muestran en la Tabla 5-3. Se puede apreciar que para una combinación de 2 y 3 días para la matriz de pesos y de 48 a 50 para los datos de entrenamiento, el residual se encuentra entre los más bajos, así mismo se presentan los resultados en forma gráfica en la Figura 5-14 donde se aprecia como la superficie de error va disminuyendo. La predicción se hizo para 24 horas

Tabla 5-3 Error medio cuadrático para diferentes combinaciones de "pesos" y días de entrenamiento

Pesos W (días)	Tiempo de entrenamiento días																																							Valor mínimo	Pesos W (días)
	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39																					
1	0.2720	0.2831	0.2903	0.3410	0.3268	0.3184	0.3180	0.3152	0.3117	0.3069	0.3002	0.2939	0.2809	0.2683	0.2597	0.2562	0.2535	0.2537	0.2502	0.2527	0.2502	1																			
2	0.3519	0.3484	0.3207	0.2996	0.3347	0.3195	0.3059	0.3039	0.3033	0.3065	0.3179	0.3218	0.3195	0.2998	0.2844	0.2817	0.2789	0.2737	0.2648	0.2483	0.2483	2																			
3	0.4570	0.4642	0.3943	0.3188	0.2904	0.3199	0.3235	0.3192	0.2982	0.2882	0.2932	0.2997	0.3090	0.3002	0.2940	0.2798	0.2898	0.2853	0.2763	0.2601	0.2601	3																			
4	0.6335	0.5948	0.6383	0.6002	0.3770	0.3859	0.2979	0.2914	0.2692	0.2521	0.2484	0.2551	0.2838	0.3299	0.3381	0.3655	0.3608	0.3598	0.3479	0.3200	0.2484	4																			
5	0.7000	0.8000	0.7800	0.5781	0.4133	0.2691	0.3091	0.3744	0.3845	0.3703	0.3381	0.3614	0.3797	0.3910	0.4147	0.4151	0.4429	0.4244	0.4260	0.3909	0.2691	5																			
6	0.9000	0.8800	0.8600	0.7600	0.7400	0.7200	0.7106	0.7000	0.5512	0.3618	0.3879	0.4099	0.4365	0.4597	0.4404	0.4912	0.4787	0.5044	0.4922	0.4984	0.3618	6																			
7	0.8800	0.8600	0.8400	0.8200	0.8000	0.7800	0.7600	0.7400	0.7000	0.6500	0.6163	0.5754	0.5018	0.5225	0.6058	0.6180	0.6038	0.5651	0.5643	0.5381	0.5018	7																			
8	1.3000	1.2400	1.2200	1.2000	1.1800	1.1600	1.1400	1.1200	1.1000	1.0800	1.0600	1.0400	1.0200	1.0000	0.9527	0.7968	0.7722	0.5938	0.4535	0.3750	0.3750	8																			
9	1.6600	1.6400	1.6200	1.8000	1.5800	1.5600	1.5400	1.5200	1.5000	1.4800	1.4600	1.4400	1.4200	1.4000	1.3800	1.3600	1.3400	1.3200	0.8908	0.5382	0.5382	9																			
10	1.7000	1.6800	1.6600	1.8400	1.6200	1.6000	1.5800	1.5600	1.5400	1.5200	1.5000	1.4800	1.4600	1.4400	1.4200	1.4000	1.3800	1.3600	1.3400	1.3200	1.3200	10																			
1	0.2525	0.2553	0.2439	0.2425	0.2428	0.2357	0.2289	0.2239	0.2199	0.2210	0.2200	0.2227	0.2236	0.2273	0.2263	0.2212	0.2226	0.2245	0.2260	0.2267	0.2199	1																			
2	0.2523	0.2515	0.2548	0.2341	0.2286	0.2249	0.2164	0.2068	0.2077	0.2057	0.2146	0.2140	0.2159	0.2165	0.2216	0.2225	0.2181	0.2202	0.2283	0.2288	0.2057	2																			
3	0.2450	0.2409	0.2421	0.2473	0.2324	0.2213	0.2189	0.2134	0.2022	0.2000	0.2022	0.2143	0.2143	0.2146	0.2161	0.2223	0.2244	0.2190	0.2164	0.2218	0.2000	3																			
4	0.2913	0.2580	0.2549	0.2624	0.2659	0.2553	0.2385	0.2266	0.2172	0.2121	0.2013	0.2027	0.2119	0.2091	0.2134	0.2153	0.2221	0.2235	0.2148	0.2087	0.2013	4																			
5	0.3563	0.3192	0.2959	0.2939	0.2998	0.2898	0.2763	0.2598	0.2679	0.2679	0.2560	0.2358	0.2377	0.2417	0.2372	0.2304	0.2243	0.2294	0.2262	0.2120	0.2120	5																			
6	0.4290	0.3891	0.3585	0.3558	0.3442	0.3599	0.3417	0.3303	0.3118	0.3245	0.3185	0.2920	0.2687	0.2608	0.2603	0.2629	0.2548	0.2439	0.2518	0.2409	0.2409	6																			
7	0.4980	0.4233	0.3947	0.3807	0.3962	0.3889	0.4099	0.3990	0.3896	0.3827	0.3903	0.3688	0.3235	0.3026	0.2898	0.2954	0.3008	0.2834	0.2716	0.2761	0.2716	7																			
8	0.3250	0.3328	0.3353	0.4010	0.4310	0.4583	0.3919	0.4105	0.4179	0.4296	0.4366	0.4563	0.4296	0.3817	0.3585	0.3597	0.3628	0.3648	0.3321	0.3150	0.3150	8																			
9	0.4629	0.4112	0.4329	0.4425	0.4394	0.4459	0.4529	0.4700	0.4295	0.4415	0.4485	0.4440	0.4378	0.4050	0.3843	0.3591	0.3614	0.3637	0.3796	0.3531	0.3531	9																			
10	1.3000	1.2533	0.7081	0.4182	0.6187	0.6833	0.7240	0.7556	0.5986	0.4302	0.4442	0.4777	0.4675	0.4829	0.4557	0.4349	0.3949	0.3732	0.3739	0.4035	0.3732	10																			
1	0.2229	0.2216	0.2235	0.2232	0.2240	0.2243	0.2207	0.2203	0.2234	0.2261	0.2292	0.2295	0.2300	0.2308	0.2322	0.2330	0.2321	0.2323	0.2323	0.2346	0.2203	1																			
2	0.2282	0.2196	0.2208	0.2239	0.2273	0.2284	0.2276	0.2250	0.2226	0.2234	0.2280	0.2282	0.2283	0.2242	0.2240	0.2273	0.2279	0.2259	0.2241	0.2250	0.2196	2																			
3	0.2220	0.2229	0.2148	0.2179	0.2260	0.2352	0.2359	0.2356	0.2327	0.2304	0.2319	0.2356	0.2367	0.2363	0.2340	0.2367	0.2395	0.2403	0.2399	0.2405	0.2148	3																			
4	0.2086	0.2083	0.2120	0.2049	0.2090	0.2177	0.2281	0.2273	0.2263	0.2244	0.2233	0.2233	0.2249	0.2275	0.2303	0.2303	0.2325	0.2354	0.2361	0.2372	0.2049	4																			
5	0.2023	0.2060	0.2036	0.2055	0.1988	0.2087	0.2173	0.2260	0.2259	0.2239	0.2239	0.2225	0.2252	0.2267	0.2233	0.2248	0.2241	0.2294	0.2332	0.2332	0.1988	5																			
6	0.2246	0.2047	0.2092	0.2027	0.2008	0.1965	0.2013	0.2110	0.2262	0.2250	0.2261	0.2279	0.2278	0.2295	0.2317	0.2332	0.2326	0.2375	0.2418	0.2448	0.1965	6																			
7	0.2594	0.2409	0.2211	0.2265	0.2212	0.2186	0.2168	0.2209	0.2280	0.2437	0.2442	0.2470	0.2528	0.2544	0.2566	0.2555	0.2565	0.2615	0.2583	0.2584	0.2168	7																			
8	0.3080	0.2953	0.2791	0.2602	0.2683	0.2616	0.2622	0.2605	0.2629	0.2706	0.2924	0.2980	0.3024	0.3006	0.3066	0.3093	0.3073	0.3126	0.3115	0.3086	0.2602	8																			
9	0.3527	0.3269	0.3054	0.2918	0.2663	0.2729	0.2739	0.2708	0.2701	0.2694	0.2764	0.3002	0.3028	0.3015	0.3016	0.3067	0.3061	0.3002	0.3104	0.3127	0.2663	9																			
10	0.4049	0.4138	0.3762	0.3426	0.3247	0.3029	0.2163	0.3095	0.2915	0.2828	0.2923	0.2936	0.3159	0.3161	0.3182	0.3174	0.3288	0.3211	0.3175	0.3295	0.2828	10																			
1	0.2358	0.2365	0.238	0.2405	0.2407	0.2392	0.2395	0.2411	0.2424	0.2415	0.2408	0.2402	0.2404	0.2387	0.2367	0.2358	0.2353	0.2348	0.2365	0.2371	0.2348	1																			
2	0.2270	0.2293	0.2285	0.2290	0.2310	0.2315	0.2292	0.2298	0.2314	0.2325	0.2297	0.2289	0.2280	0.2292	0.2276	0.2274	0.2270	0.2267	0.2281	0.2310	0.2267	2																			
3	0.2419	0.2435	0.2470	0.2449	0.2435	0.2446	0.2447	0.2437	0.2424	0.2435	0.2450	0.2427	0.2414	0.2404	0.2405	0.2382	0.2372	0.2353	0.2325	0.2328	0.2325	3																			
4	0.2368	0.2381	0.2394	0.2423	0.2405	0.2367	0.2355	0.2338	0.2328	0.2296	0.2304	0.2342	0.2344	0.2349	0.2338	0.2328	0.2305	0.2286	0.2282	0.2266	0.2266	4																			
5	0.2328	0.2327	0.2340	0.2310	0.2320	0.2282	0.2239	0.2213	0.2190	0.2195	0.2171	0.2190	0.2223	0.2225	0.2217	0.2229	0.2223	0.2196	0.2196	0.2213	0.2171	5																			
6	0.2436	0.2425	0.2446	0.2449	0.2409	0.2441	0.2417	0.2365	0.2330	0.2315	0.2328	0.2300	0.2343	0.2390	0.2397	0.2379	0.2394	0.2386	0.2360	0.2365	0.2300	6																			
7	0.2591	0.2550	0.2558	0.2601	0.2604	0.2555	0.2575	0.2577	0.2535	0.2515	0.2498	0.2488	0.2441	0.2469	0.2491	0.2472	0.2448	0.2458	0.2445	0.2416	0.2416	7																			
8	0.3108	0.3126	0.3079	0.3093	0.3155	0.3137	0.3051	0.3070	0.3058	0.3035	0.3023	0.2979	0.2951	0.2899	0.2942	0.2937	0.2923	0.2878	0.2895	0.2873	0.2873	8																			
9	0.3090	0.3069	0.3095	0.2983	0.2987	0.3008	0.2988	0.2901	0.2934	0.2921	0.2987	0.2874	0.2847	0.2841	0.2784	0.2820	0.2770	0.2770	0.2750	0.2756	0.2750	9																			
10	0.3338	0.3193	0.3171	0.3121	0.2965	0.2972	0.2994	0.3012	0.2895	0.2921	0.2913	0.2907	0.2906	0.2896	0.2931	0.2861	0.2899	0.2848	0.2822	0.2834	0.2822	10																			

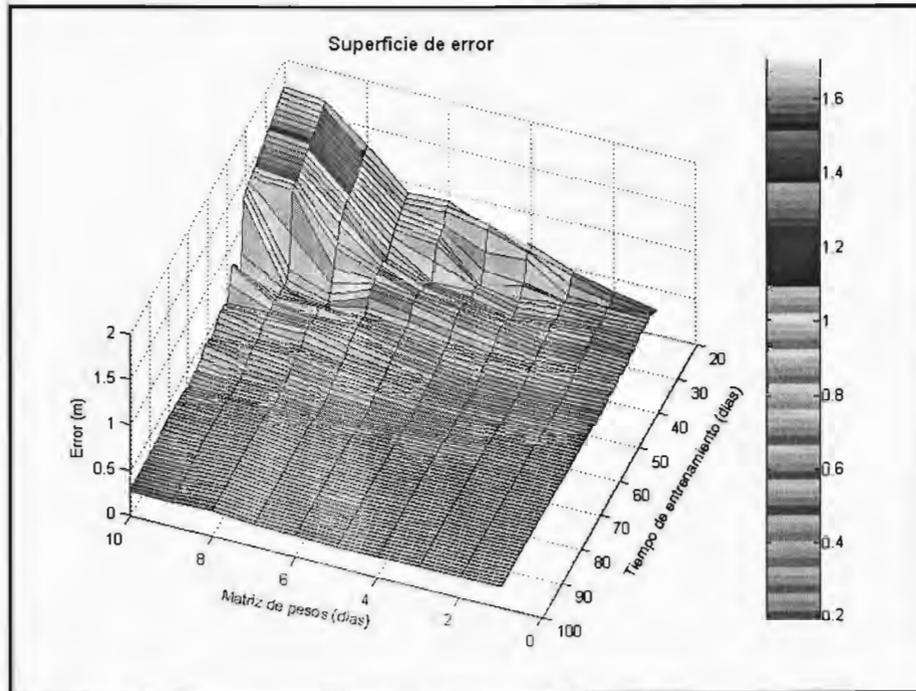


Figura 5-14 Superficie de error para predicción con residual marea astronómica, presión y vientos

Con los resultados anteriores se llevó a cabo la predicción de marea para los días 9,10 y 11 de octubre con 3 días para la matriz de pesos y 49 días de entrenamiento obteniendo los resultados mostrados en la Figura 5-15 donde a simple vista se aprecia que aunque el ajuste entre la marea real y la predicción con la RNA no es exacta tiene un mejor comportamiento que la predicción con componentes armónicos (línea continua).

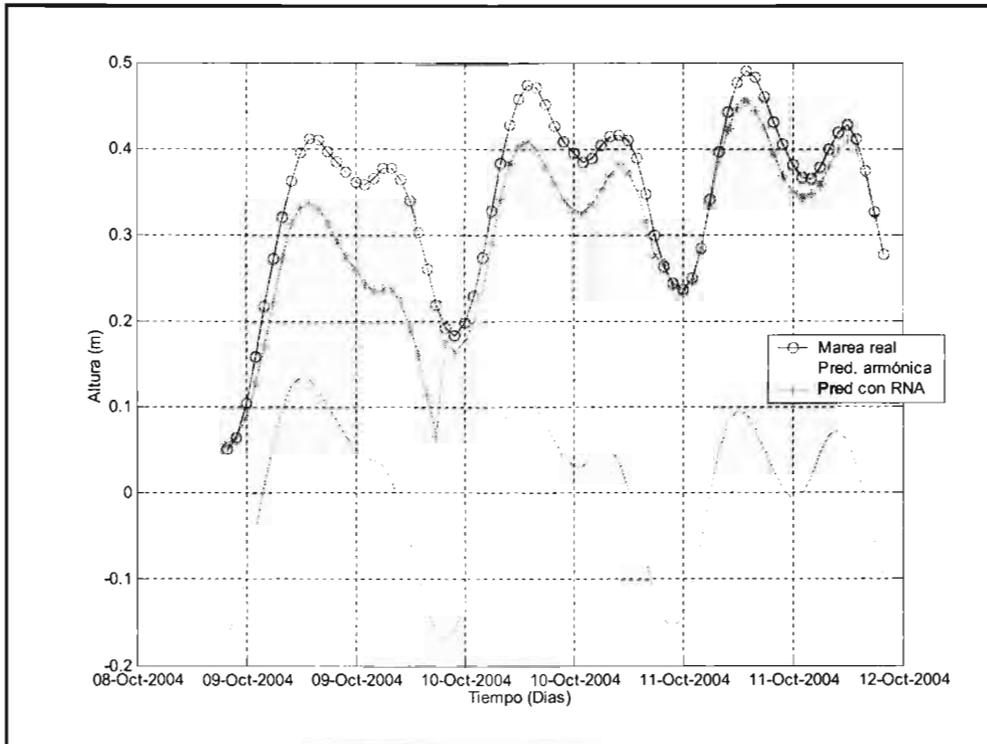


Figura 5-15 Predicción de marea real con datos de marea astronómica, residual, viento y presión

5.6.1 Comparación entre la predicción con redes neuronales y componentes armónicos

Con la finalidad de mostrar la conveniencia de utilizar redes neuronales para la predicción de la marea, a continuación se hace una comparación entre la predicción con RNA y la predicción con componentes armónicos en relación a la marea registrada en el sitio.

El error entre la predicción con componentes armónicos con la marea real y el error entre la predicción con RNA y la marea real, se obtuvo de acuerdo a la ecuación (22) que obtiene el porcentaje de error tomando como referencia la amplitud de la marea registrada en el intervalo de tiempo considerado.

$$error = \frac{\left(\frac{1}{N} \sum (H - X)^2 \right)^{1/2}}{H_{rms}} \quad (22)$$

donde H es el nivel de agua observado, X es el nivel de agua obtenido con RNA, N es el número de horas de la predicción, H_{rms} es el nivel de agua medio cuadrático en el tiempo de la predicción (en este caso 24 hrs).

El error para los dos tipos de predicción mencionados se muestra en la Figura 5-16 en la cual se puede observar el porcentaje de error para cada día, manteniéndose en los tres casos menor al 20% y para los días 10 y 11 menor al 10% con RNA.

Esta gráfica muestra la utilidad de la predicción con RNA ya que, debido seguramente a un fenómeno meteorológico, la marea real muestra una sobrelevación importante del nivel de la superficie libre, que no toma en cuenta la predicción con componentes armónicos.

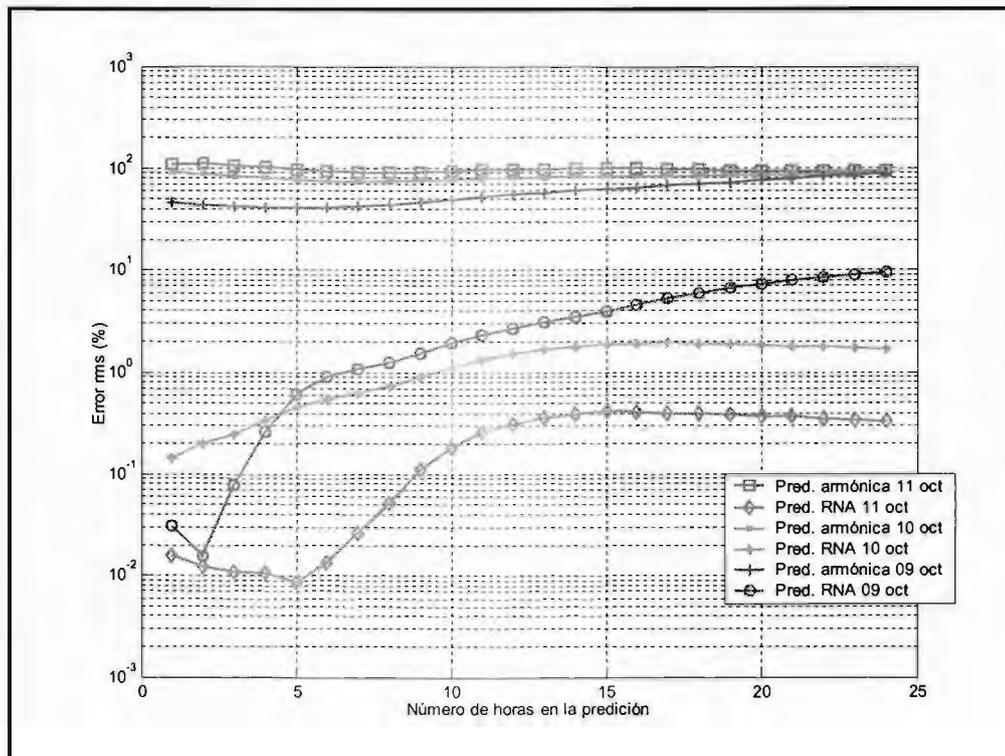


Figura 5-16 Comparación del error entre predicción con componentes armónicos y RNA en la zona donde existe una perturbación importante

Aunque la estimación de la marea real con RNA de la Figura 5-15 es mejor que la predicción de la marea con componentes armónicos se puede observar que la predicción con RNA aún se encuentra alejada de la marea real, aunque se hayan ingresado datos de viento y presión. Por lo tanto se hizo una comparación de la predicción sin presión y posteriormente sin vientos para ver si los resultados mejoraban o empeoraban. A continuación en las Figura 5-17 y Figura 5-18 se presenta la predicción para estas dos condiciones y finalmente en la Figura 5-19 la comparación del error, donde se puede concluir que el viento y la presión en este caso no mejoran la predicción. Lo anterior es debido a que no existe una fuerte correlación entre el aumento de la marea y los vientos o la presión locales (Figura 5-4), por lo tanto la estimación de la marea en esta zona del registro es mejor no considerando vientos ni presión. Esto no quiere decir que los vientos y la presión no mejoren la predicción, si no que, en esta parte del registro los vientos y la presión local no son los factores responsables de la sobrelevación.

La sobrelevación en esta parte del registro se cree es debida a la temporada de huracanes ya que como se observa en la Figura 5-20 la sobrelevación de mayor magnitud en el registro se presenta aproximadamente en el mismo periodo de la temporada de huracanes.

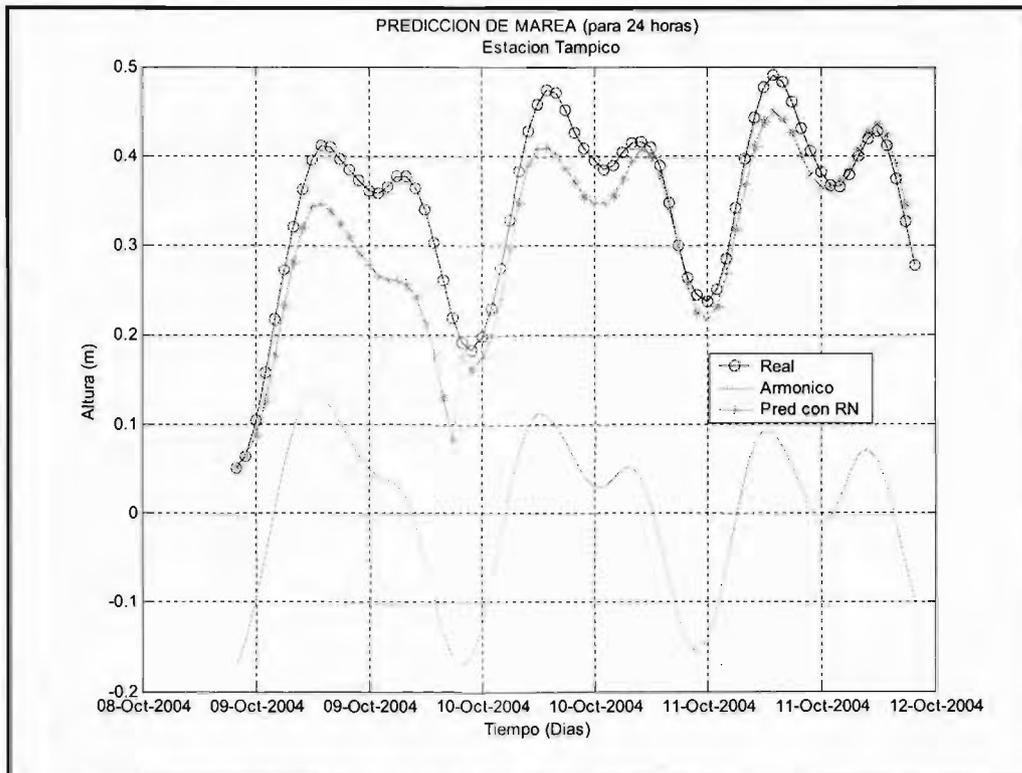


Figura 5-17 Predicción para los días 09 al 11 de octubre ingresando componentes armónicos, residual y viento

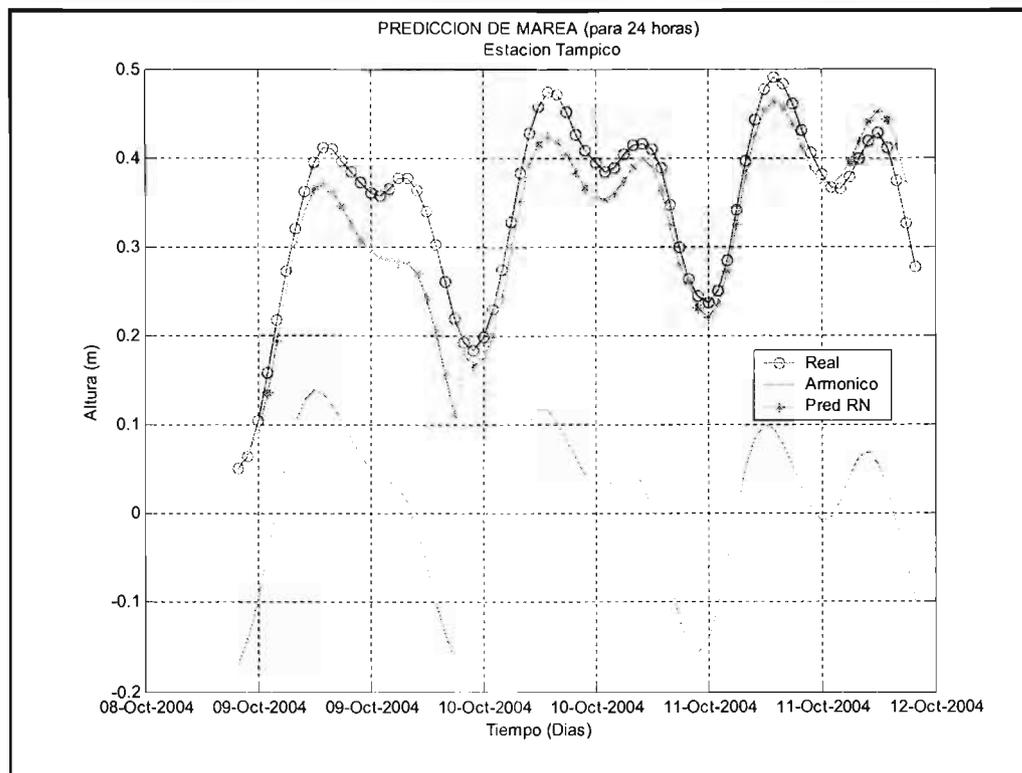


Figura 5-18 Predicción para los días 09 al 11 de octubre ingresando solo componentes armónicos y residual

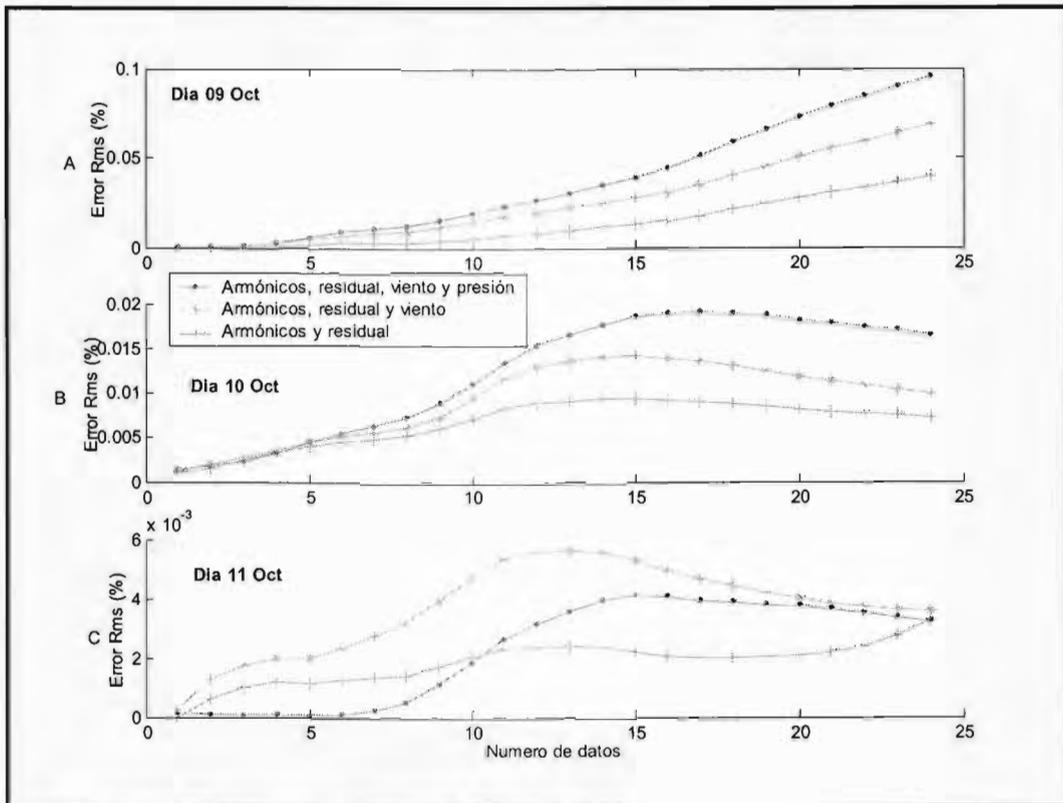


Figura 5-19 Comparación entre la predicción para los días del 09 al 11 considerando diferentes datos de entrenamiento

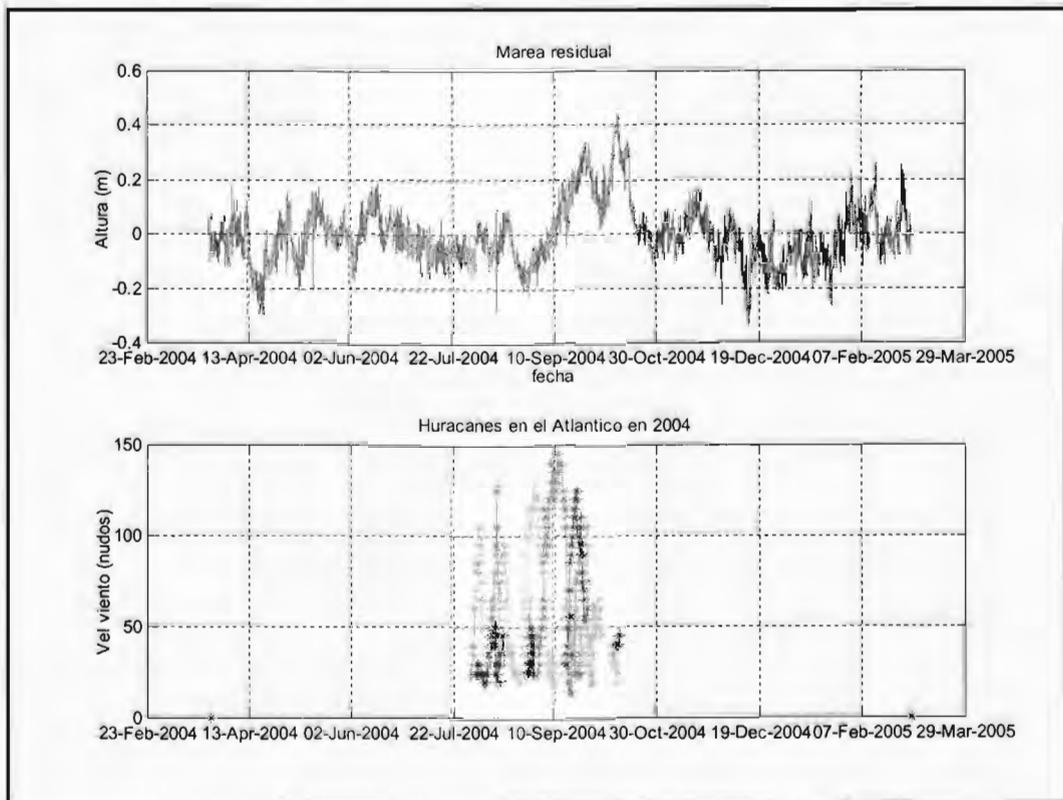


Figura 5-20 Gráfica de residual y huracanes en el año 2004

5.6.2 Importancia de datos de viento y presión en la predicción de marea con RNA

Con la red neuronal ADALINE se hizo la predicción de los días 21 y 22 de diciembre donde se puede apreciar una clara diferencia entre la marea registrada y la marea astronómica, pero en estos días ya no se registraron huracanes. Por lo tanto esta sobrelevación debe ser consecuencia de las condiciones locales.

En el apartado 5.6.1 se llegó a la conclusión que para los días 9 a 11 de octubre los registros de viento y presión no mejoraban la predicción, Sin embargo, si se toman en cuenta los datos de viento y presión en la estación mareográfica para la predicción del 21 y 22 de diciembre, se puede decir que dichos datos mejoran la predicción cuando la perturbación de la marea es debida a eventos meteorológicos locales (ver Figura 5-21). Por lo tanto se puede concluir que las redes neuronales tienen un mejor desempeño en la predicción de la marea si se alimentan con todos los factores que influyen en la marea, como pueden ser:

- Marea astronómica
- Marea residual
- Viento local
- Presión local
- Viento y presión de frentes fríos ("nortes")
- Huracanes.

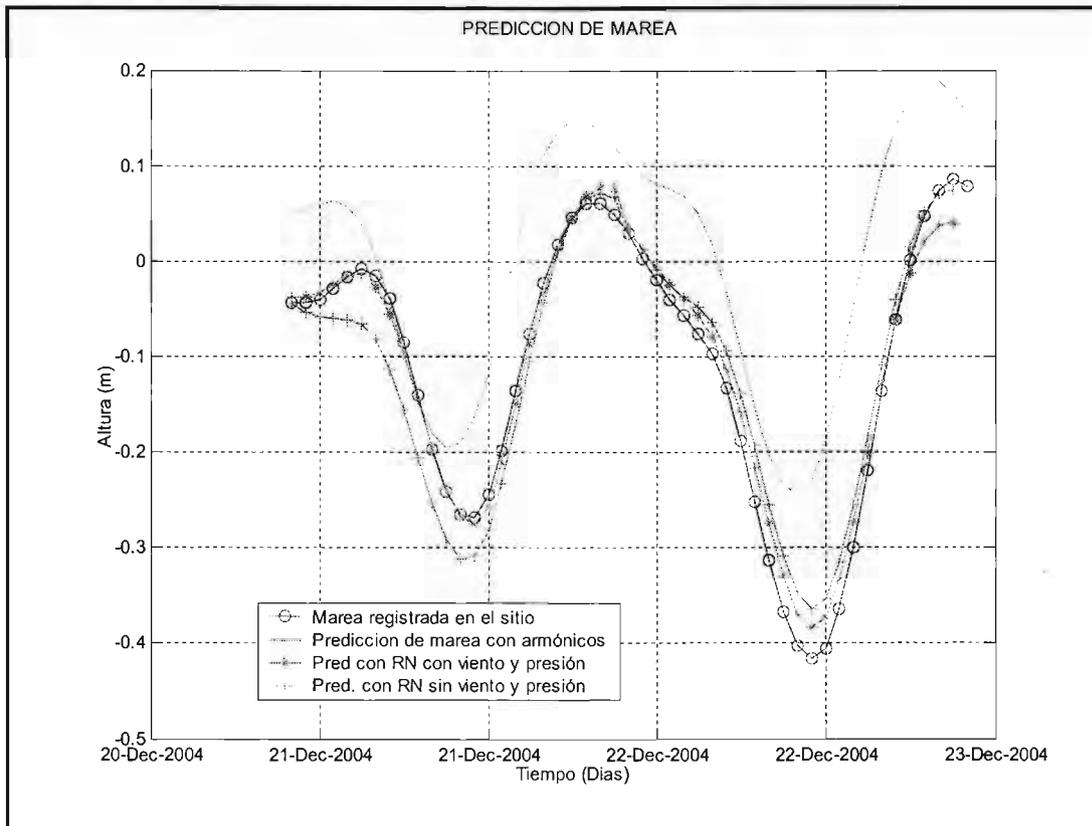


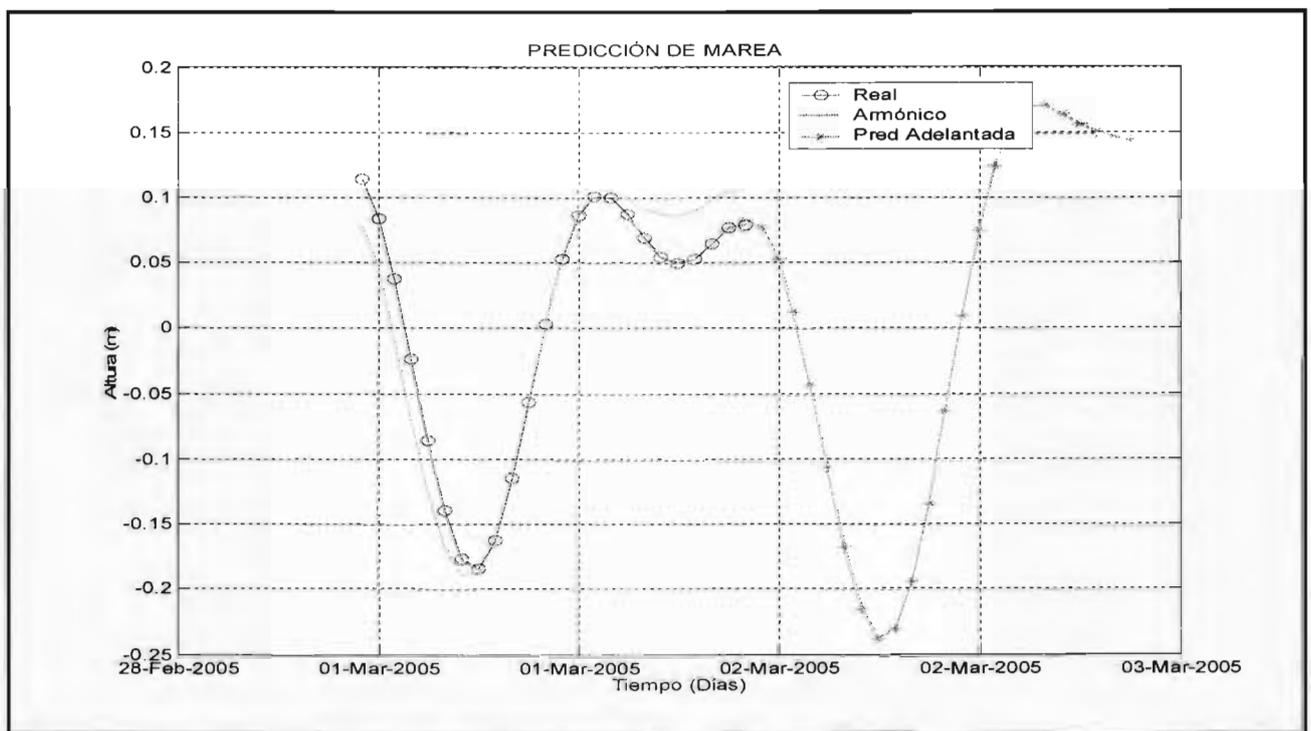
Figura 5-21 Comparación entre dos predicciones con y sin datos de viento y presión

5.7 Ejemplo práctico de predicción con redes neuronales

Para comprobar el buen funcionamiento de la red neuronal seleccionada y la disposición de datos del Internet, se tomaron los datos del sitio Web mencionado anteriormente de Tampico, desde el primer día de registro (24 de marzo del 2004) hasta el día 01 de marzo del 2005 y se hizo la predicción a 24 horas para el día 02 de marzo 2005

La estimación de la marea para el día 02 de marzo se muestra en la Figura 5-22. El día 03 de marzo se obtuvieron los datos de marea del sitio Web y se compararon con la predicción. Para los días 04 y 05 de marzo se hizo el mismo procedimiento los resultados se muestran en las figuras: Figura 5-23, Figura 5-24, Figura 5-25, y Figura 5-26.

Cabe mencionar que este ejercicio de predicción solo fue hecho con la marea astronómica y residual ya que no se contaba en su momento con más información; los datos de viento y presión del SMN solo se tenían hasta el 31 de diciembre de 2004.



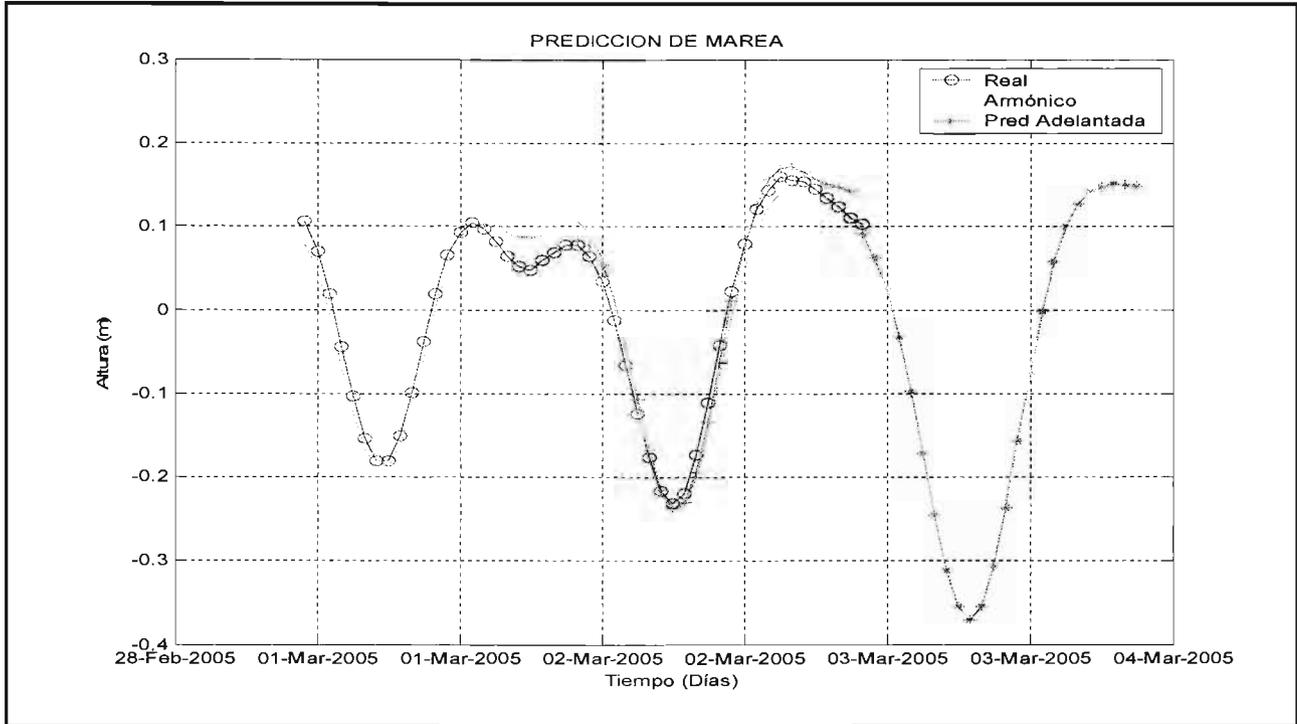


Figura 5-23 Comparación entre medición y predicción para el 02 de marzo y predicción para el 03 de marzo

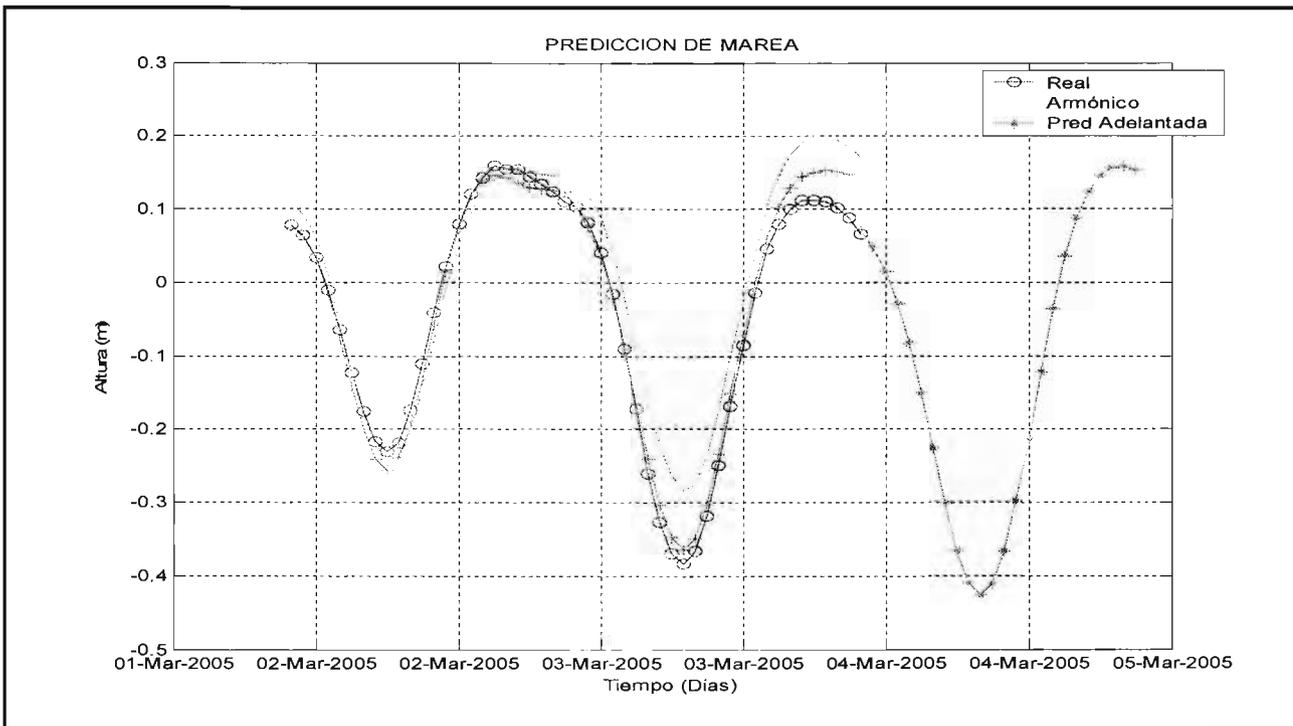


Figura 5-24 Comparación entre la medición de marea y la predicción del día 03 de marzo y predicción para el día 04 de marzo

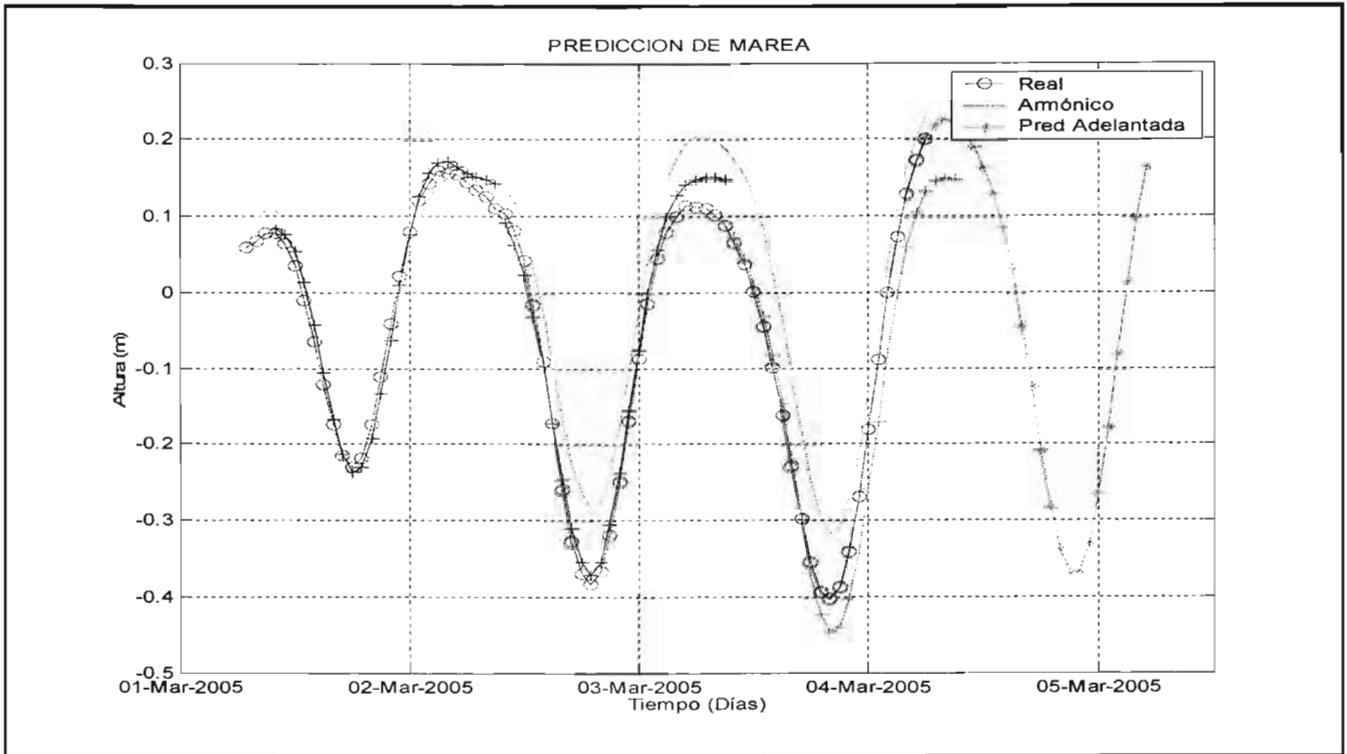


Figura 5-25 Comparación entre la medición de marea y la predicción para el día 04 de marzo y predicción para el día 05 de marzo

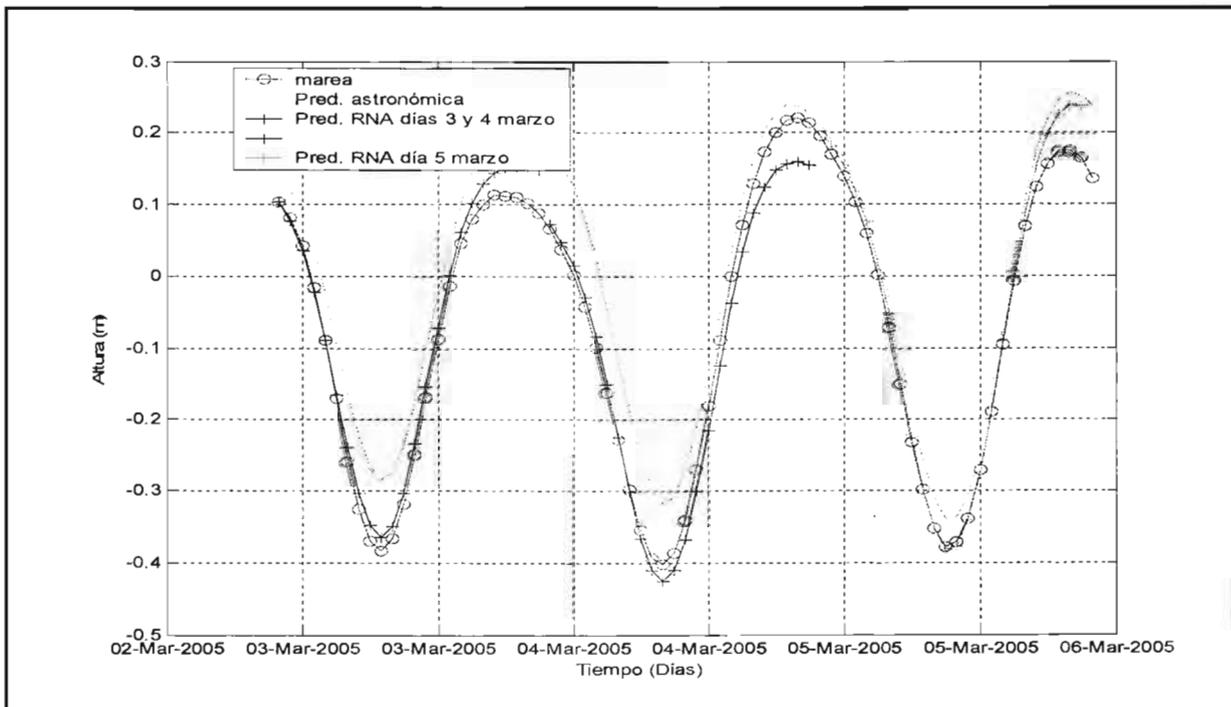


Figura 5-26 Comparación entre medición y predicción para el 05 de marzo

A simple vista se puede ver que hay un buen ajuste en las primeras horas de predicción entre la marea real y la predicción con RNA, pero al hacer la predicción de mayor tiempo, el error crece significativamente. Para tener una idea de la magnitud del error y su propagación a lo largo del tiempo, se obtuvo el porcentaje de error con la ecuación (22).

En la Figura 5-27 se muestra cuantitativamente el error para cada día de predicción. En esta misma grafica se concluye que cuanto mayor es el número de horas en la predicción mayor es el error, sin embargo, mismo para el día 04 de marzo (rojo en la grafica, Figura 5-27) que tiene el mayor error al final de las 24 horas de predicción con 22% aproximadamente, dicho error solo representa 11 cm de diferencia entre la predicción y la medición, ya que la amplitud de marea en este día es de aproximadamente 50 cm. También se puede observar que para 12 horas de predicción en todos los casos el error se encuentra por debajo de 10% lo cual para fines prácticos es aceptable, en caso de que se pueda hacer dicha predicción y publicarla en la red en un tiempo mucho menor que 12 horas para que se pueda aprovechar.

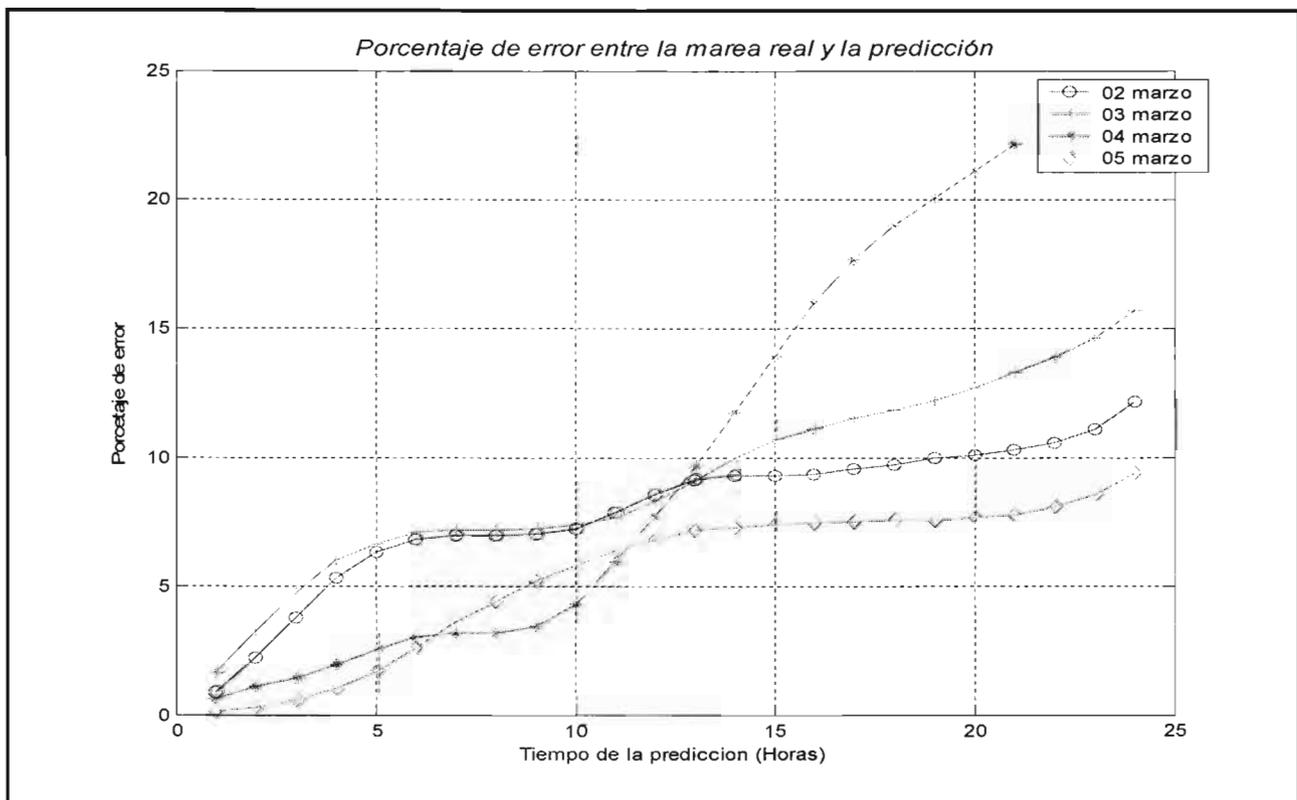


Figura 5-27 Porcentaje de error entre la marea real y la predicción con RNA para los días considerados

Como se vio en el apartado anterior, es probable que la predicción hubiera mejorado si se consideran datos de presión y viento.

6 Conclusiones

Resumen

Este trabajo presentó un método, basado en Redes Neuronales Artificiales (RNA), a partir del cual se puede predecir la marea real, la cual difiere significativamente de la marea astronómica en algunas zonas costeras de la República Mexicana (por ejemplo el Golfo de México), particularmente en algunas épocas del año donde eventos meteorológicos de intensidades medias o altas generan mareas extraordinarias.

En la actualidad, tanto ingenieros como dependencias de gobierno (municipales, estatales y federales) se basan en las tablas de predicción de mareas para el diseño y toma de decisiones en aspectos relativos al nivel del mar en la costa. Sin embargo, como se pudo observar en las gráficas presentadas, en muchos de los casos la predicción de marea obtenida con análisis armónico no se ajusta correctamente a la marea registrada por el mareógrafo, ya que este análisis no toma en cuenta eventos meteorológicos de corta duración como huracanes y frentes fríos.

Como ejemplo, y a partir de datos de un mareógrafo de Tampico proporcionados por el proyecto ROPVO-GM, se vió que una importante anomalía de la marea se presentó en el mes de septiembre, por lo cual se buscó una arquitectura de red neuronal que fuera capaz de estimar dicha sobrelevación, ingresando datos de elevación del nivel del mar y adicionalmente parámetros de presión y viento anteriores a esta sobrelevación. Para esto se utilizó en primera instancia una red multicapa con algoritmo de retropropagación con dos capas, una capa intermedia con función de transferencia logsig y una capa de salida con función de transferencia lineal. Esta red neuronal fue capaz de predecir satisfactoriamente la marea astronómica, pero no así la marea residual.

Posteriormente se utilizó una red neuronal con una sola neurona y función de transferencia lineal observando el mismo comportamiento que la red multicapa. Por lo que se decidió cambiar la forma de entrenamiento para esta última por tener un algoritmo de entrenamiento más sencillo y tener una precisión en la predicción similar a la red multicapa.

El método de entrenamiento consistió en ingresar separadamente datos de entrada de: marea astronómica, residual, viento y presión, esperando como respuesta de la red neuronal la marea real registrada en este periodo. La red neuronal trabajó satisfactoriamente dando una buena aproximación, significativamente mejor que la predicción con componentes armónicos. Sin embargo, se observó una mejoría adicional en uno de los ejercicios realizados, ingresando solo datos de marea astronómica y residual, sugiriendo que para el periodo analizado los datos de viento y presión presentados no eran los responsables de dicha sobrelevación. En otro ejercicio realizado en un periodo del registro para el cual la temporada de huracanes había terminado los datos de viento y presión si mejoraban la predicción.

Ventajas y Desventajas

La exactitud en la estimación de la elevación del agua puede cambiar significativamente en época de huracanes o nortes, sin embargo esto puede ser corregido si se tienen datos de los mismos oportunamente.

El intervalo de tiempo de la predicción depende mucho del error que el usuario este dispuesto a aceptar. Sin embargo como se mostró anteriormente el error se encuentra por debajo de 10% para 12 horas de predicción, comparado hasta con 100% si se usa la predicción de la marea astronómica en temporada de nortes y huracanes. Cabe señalar que si no existen perturbaciones atmosféricas importantes la predicción con componentes armónicos tendrá menor que error que la predicción con RNA sin embargo este error siempre se mantendrá por debajo del 10%

Con el fin de aprovechar al máximo esta técnica de predicción de marea en sitios de interés en la costa, no se requiere ni de equipo de cómputo, ni tampoco de técnicos especializados, pero es indispensable contar con una red mareográfica en tiempo real.

Aportaciones

Se podrán consultar en Internet las predicciones para los puertos de Tampico y Mezquital y más adelante los puertos de la Pesca, Tuxpan y Veracruz, presentando predicción armónica y residual.

Las redes neuronales para predicción de mareas, así como la red mareográfica nacional servirán para calibrar otros modelos hidrodinámicos.

Con la predicción de marea se pueden delimitar zonas de riesgo en una tormenta e implementar un sistema de alarma y prevención de desastres por inundación

Con el uso de este tipo de herramienta para predecir el nivel del mar se podrán optimizar las operaciones portuarias y planear con menor grado de incertidumbre las obras portuarias (alturas de desplante, zonas de inundación, planear el transito de las embarcaciones en puertos, etc.)

Futuras líneas de estudio

Con datos de marea y oleaje en alta mar y en la costa se podrá estimar la transformación del oleaje de aguas profundas a aguas someras así como anticipar una sobrelevación importante en la costa con datos anticipados de lo que ocurre en altamar.

Las redes neuronales se podrán aplicar a otros modelos de procesos costeros con menos consumo de recursos computacionales obteniendo un grado de exactitud aceptable para la mayoría de las aplicaciones de ingeniería.

La predicción de la sobrelevación por tormenta se podrá lograr con mayor precisión si se ingresan los datos de los avisos de huracanes publicados cada seis horas.

Referencias

- O. Bajo Rubio, S. Sosvilla Rivero, F. Fernandez Rodriguez, (2002): Non-linear Forecasting Methods: Some Applications to the Analysis of Financial Series, FEDEA
- Bautista Godínez Eric Gustavo, Silva Casarín Rodolfo, Salles A. de Almeida Paulo, (2003): Predicción de marea de tormenta generada por ciclones tropicales. Ingeniería hidráulica en México, vol. XVIII, núm. 2, pp 5-19
- Bollerslev, T. (1986): "Generalized autoregressive conditional heteroskedasticity", Journal of Econometrics, Vol. 31,
- Bowles, Z. Tissot, P.E. Michaud, P and Sadouski, (2003): Artificial Neural Network Predictions of water levels in a Gulf of Mexico Shallow Embayment, Third international conference on multivariate approximation Theory and Applications, Cancún, Mexico
- G. Box & G. Jenkins, (1976): Time-series Analysis, Forecasting and Control (Prentice Hall, Englewood Cliffs).
- M. Casdagli & S. Eubank (Editores) (1992): Nonlinear Modeling and Forecasting, SFI Studies in the Sciences of Complexity (Adisson-Wesley Longman, Reading).
- Cherkassky, V., Friedman, J.H. y Wechsler, H. (eds.) (1994). From statistics to neural networks. Springer- Verlag.
- Croall, I.F. y Mason, J.P. (1992): Industrial applications of neural networks. Springer-Verlag. N.Y.
- Danilo P Mandic, Jonathon A. Chambers, (2001): "Recurrent Neural Networks for Prediction", Wiley
- Diebold, F. X. and Nason, J. (1990): "Nonparametric exchange rate prediction?", Journal of International Economics, Vol. 28.
- Engle, R. F. (1982): "Autoregressive conditional heteroskedasticity with estimates of the variance of U. K. inflation", Econometrica, Vol. 50.
- Garson, G.D. (1991). A comparison of neural network and expert systems algorithms with common multivariate procedures for analysis of social science data. Social Science Computer Review.
- T Hagan, Howard B Demuth, Mark H Beale, (1996): Neural Network Design, PWS publishing company

- Tissot E Phillippe, Cox T Daniel, M.ASCE, and Patrick Michaud, (2001): Neural Network forecasting of storm surges along the gulf of Mexico, Proceedings Ocean Wave Measurement and Analysis vol 2. ASCE pp 1535-1544
- D. O. Hebb, (1949): "The Organization of Behavior", New York: Wiley.
- J. J. Hopfield, (1982): "Neural networks and physical systems with emergent collective computational abilities", Proceedings of the National Academy of Sciences, Vol. 79
- Huang, W.Y. y Lippmann, R.P. (1987): Comparisons between neural nets and conventional classifiers. Proceedings of the IEEE International Conference on Neural Networks, I.
- Lewis, P. A. W., Ray, B. K. and Stevens, J. G. (1994): "Modeling time series using multivariate adaptive regression splines (MARS)", in A. S. Weigend and N. A. Gershenfeld (eds.): Time Series Prediction: Forecasting the Future and Understanding the Past (Reading, MA: Addison Wesley).
- Martín, B. y Sanz, A. (1997): Redes neuronales y sistemas borrosos. Ra-ma. Madrid.
- Mase, H., Sakamoto, M., and Sakai, T. (1995): "Neural network for stability analysis of rubble-mound breakwaters," J. Wtrwy., Port, Coast, and Oc. Engrg., ASCE, 121 (6), 294-299.
- McCulloch Warren and Pitts Walter, (1943): "A logical calculus of the ideas immanent in nervous activity," Bulletin of Mathematical Biophysics., Vol. 5, pp. 115-133
- Michie, D., Spiegelharter, D.J. y Taylor, C.C. (eds) (1994): Machine learning, neuraland statistical classification. Londres: Ellis Horwood.
- M. Minsky and S. Papert, (1969). Perceptrons, Cambridge, MA:MIT Press.
- Pawlowicz, R., B. Beardsley, and S. Lentz (2002): "Classical Tidal "Harmonic Analysis Including Error Estimates in MATLAB using T_TIDE").
- Pitarque A., Roy J. F., y Ruiz J. C. (1998): "Redes neurales vs modelos estadísticos: Simulaciones sobre tareas de predicción y clasificación". Universidad de Valencia
- Ripley, B.D. (1993): Statistical aspects of neural networks. En O.E. Barndorff-Nielsen, J.L. Jensen y W.S. Kendall (eds), Networks and chaos: Statistical and probabilistic aspects. Londres: Chapman and Hall.
- D. E. Rumelhart and J. L. McClelland, eds., (1986): Parallel distributed Processing: Explorations in the Microstructure of Cognition, Vol. 1, Cambridge, Ma: MIT Press.
- F. Rosenblatt, (1958): "The perceptron: A probabilistic model for information storage and organization in the brain," Psychological Review, Vol. 65, pp. 356-408.

- Sarle, W.S. (1998): Neural network FAQ. Acceso FTP, parts 1 to 7. Acceso FTP:<ftp://ftp.sas.com/pub/neural/FAQ.html>
- Schureman, P. (1924): "Manual of Harmonic Analysis and Prediction of Tides," Special Publication No. 98, U.S. Department of Commerce, Coast and Geodetic Survey, U.S. Government Printing Office, Washington, DC.
- Smith, M. (1993): Neural networks for statistical modelling. Van Nostrand Reinhold. N.Y.
- J. A. K. Suykens & J. Vandewalle (Eds.), (1998): Nonlinear Modeling Advanced Black-Box Techniques (Kluwer Academic Press, Amsterdam).
- Thrun, S., Mitchell, T. y Cheng, J. (1991): The MONK's comparison of learning algorithms. Introduction and survey. En S. Thrun, J. Bala, E. Bloedorn e I. Bratko (eds.), The MONK's problem. A performance comparison of different learning algorithms. Pittsburg: Carnegie-Mellon Univ.
- Tsai, C.-P. and Lee, T.-L. (1999): "Back-propagation neural network in tidal-level forecasting," J. Wtrwy. Port, Coast. Oc. Engrg. 125, 4, 195-202.
- Trippi, R. R. (ed.) (1995): Chaos & Nonlinear Dynamics in the Financial Markets. Theory, Evidence and Applications (Chicago: Irwin).
- Vaziri, M (1997): "Predicting Caspian Sea surface water level by ANN and ARIMA models" J. Wtrwy., Port, Coast. And Oc. Engrg., ASCE, 123 (4), 158-162
- White, H. (1994): Parametric statistical estimation with artificial neural networks. En Smolensky, Mozer y Rumelhart (eds.), Mathematical perspectives on neural networks. Hillsdale, NJ: Erlbaum.
- B. Widrow and M. E. Hoff, (1960): "Adaptive switching circuits," 1960 IRE WESCON Convention Record, New York: IRE Part 4, pp. 96-104.

Anexo A código en matlab "predicción de mareas"

```

%Programa para prediccion de mareas con redes neuronales
%Autor Jose Lopez Gonzalez
%Revision: 09-Aug-2005
%*****
%nombre del archivo de datos en tiempo y alturas
%dat='Mtampico1.txt'
%G=load('m11octl');
G=load('04agosto');
%G=load('25mar31d');
dt=G(2)-G(1);%intervalo de tiempo de los datos en horas
XIN=G(:,2);%elevaciones
npts=length(XIN);%numero de puntos
t=G(:,1);%vector de tiempo en horas
fi=t(1);tf=t(npts);%tiempo inicial y tiempo final
VR=[];
%*****
%Se cargan los datos de Viento y Presion a cada 10 min
%*****
%Presion
load 'vientos.txt'
dias=vientos(:,1);
min=vientos(:,2);
dir=vientos(:,3);
iv=vientos(:,4);
Pres=vientos(:,5)-1013;
tv=(dias+693960)*24+min/(60);%Tiempo de los datos de presion en horas
th=fix(tv(end)-tv(1));%horas de medicion
x=(tv(1):tv(1)+th);%vector de tiempo a cada hora para interpolar
ph=interp1(tv,Pres,x);%presion a cada hora
%Vientos
vh=interp1(tv,iv,x);
dirh=interp1(tv,dir,x);
angX=deg2rad(dirh-90);
U=vh.*cos(angX);U=U';
V=vh.*sin(angX);V=V';
%compass(U,V)
%quiver(U,V)
%rose(angX,vh)
%*****
%Se procesan los datos de marea
%Se quitan los primeros y los ultimos valores si estos son NaN
IVal=find(~isnan(XIN));
Xmed= mean(XIN(IVal));%Promedio sin tomar en cuenta los NaN
INaN=find(isnan(XIN));
nptsNaN=length(INaN);
if nptsNaN>=1
    VR=INaN(1)-1;
    for ii=1:nptsNaN-1
        a1=INaN(ii);
        a2=INaN(ii+1);
        dif1=a2-a1;
        if dif1>1
            VR=[VR;INaN(ii)+1;INaN(ii+1)-1];
        end
    end
end

```

```

end
VR=[VR;INaN(end)+1]; %vector de rangos NaN
if VR(1)<=1
    in1=VR(2)+1;
else
    in1=1;
end
if VR(end)>=npts
    in2=VR(end-1)-1;
else
    in2=npts;
end
XIN=XIN(in1:in2);
t=t(in1:in2);
end
VR=[]
%*****
%Se interpola en donde todavia hay NaN se tendria que poner una condicion
%de tiempo
INaN=find(isnan(XIN));
nptsNaN=length(INaN);
if nptsNaN>=1
    VR=INaN(1)-1;
    for ii=1:nptsNaN-1
        a1=INaN(ii);
        a2=INaN(ii+1);
        dif1=a2-a1;
        if dif1>1
            VR=[VR;INaN(ii)+1;INaN(ii+1)-1];
        end
    end
end
VR=[VR;INaN(end)+1]; %vector de rangos NaN
end
%Se interpola
for ii=1:2:length(VR)
v1=XIN(VR(ii));v2=XIN(VR(ii+1));nptsI=VR(ii+1)-VR(ii);
nm=linspace(v1,v2,nptsI+1);
XIN(VR(ii):VR(ii+1))=nm;
end
%*****
%Se realiza el analisis armonico con el programa t-tide
[NAME,FREQ,TIDCON,XOUT]=T_TIDE(XIN,'interval',dt);
Xmed2=mean(XIN)
XIN1=XIN-Xmed2;
Xdif=XIN1-XOUT;
%plot(t,XIN1,t,XOUT)
%Se le aplica un filtro para frecuencias con T<1 hr a la diferencia
%de marea astronomica y marea real
%*****
%low pass el filtro deja las señales menores o iguales que F2
F2=1300; %Hz
s=XIN1;
[b1,aa1] = ELLIP(4,.5,20,[F2]*2/npts,'low');
sf3 = filter(b1,aa1,s);
%mover la marea filtrada para que se ajuste mejor a la marea real
aj=8; %horas para ajuste

```

```

p48a=s(1:aj/.10);
p48b=sf3(1:aj/.1);
e1=(sum(p48a-p48b).^2)^5;
ii=1;
Mfilt=sf3(1+ii:aj/.1+ii);
e2=(sum(Mfilt-p48a).^2)^5;
while e2<e1
ii=ii+1;
e1=e2;
Mfilt=sf3(1+ii:aj/.1+ii);
t2=t(1:aj/.1);
e2=(sum(Mfilt-p48a).^2)^5;
end
ii=ii-1
Mfilt=sf3(ii+1:end);
MareaArm=XOUT(1:end-ii)
Residf=Xdif(ii+1:end)
tf=t(1:end-ii);
plot((t+fi)/24,s,(tf+fi)/24,Mfilt,(t+fi)/24,sf3,(tf+fi)/24,MareaArm)
title('MAREA')
xlabel('Tiempo (Dias)')
ylabel('Altura (m)')
legend('Real','Filtrado mov','Filtrado','Armonico')
dateaxis('X',1)
grid
%*****
%Se cargan los datos de marea filtrados a cada hora y los de presion
%presion=load('presionh.txt');
%viento=
%*****
%REDES NEURONALES
%*****
%Datos, Se ponen todas las variables que se pueden cambiar
Numhp=24;      %numero de horas a predecir
Numdp=1;      %numero de los ultimos dias a predecir
NumW1=3;      %numero de dias para encontrar los pesos
NumDEnt1=49;  %numero de dias para entrenamiento
%Una vez que se ha filtrado la marea se obtienen datos a cada hora
numD=length(Mfilt);%cantidad de datos de la marea
indH=(11:10:numD); %vector de indices para cada hora
tiempo=tf(indH);
MrealH=Mfilt(indH);
MareaArm=MareaArm(indH); %marea armonica
Resid=Residf(indH);
%plot(tiempo,MrealH,tiempo,MareaArm)
%*****
%Calculos iniciales en horas
NumW=NumW1*24; %numero de dias para encontrar los pesos
NumDEnt=NumDEnt1*24; %numero de dias para entrenamiento
Numdp=Numdp1*24; %numero de los ultimos dias a predecir
numdat=length(MareaArm);
NdatEnt=Numdp+NumDEnt+Numhp;
ini=numdat-(NdatEnt-1);
%creacion de la matriz de entrenamiento
if (numdat-NdatEnt)>0
    R=[];tr=[];e=[];

```

```

for j=0:Numhp:(Numdp)
    Dia=(j/Numhp+1)*(Numhp/24)
    P=[];T=[];P1=[];PA=[];PB=[];PC=[];;PD=[];PE=[];
    t1=0;
    t2=0;
    indP1=ini+j;    %indices de la matriz de entrenamiento
    indP2=ini+NumDEnt-NumW-1+j;
    for ii=0:NumW-1
        %PA(ii+1,1:NumDEnt-NumW)=ph(indP1+ii:indP2+ii);%presion
        PB(ii+1,1:NumDEnt-NumW)=MareaArm(indP1+ii:indP2+ii);%marea armonica
        PC(ii+1,1:NumDEnt-NumW)=Resid(indP1+ii:indP2+ii);%Residual
        %PD(ii+1,1:NumDEnt-NumW)=U(indP1+ii:indP2+ii);%viento E-W
        %PE(ii+1,1:NumDEnt-NumW)=V(indP1+ii:indP2+ii);%viento N-S
        t1(ii+1,1:NumDEnt-NumW)=tiempo(indP1+ii:indP2+ii);
    end
    %P=[PA;PB;PC];
    %P=[PA;PB;PC;PD;PE];
    P=[PB;PC];
    %P=[PB;PC;PD;PE];

    for ii=0:Numhp-1
        T(ii+1,1:NumDEnt-NumW)=MrealH(indP1+ii+NumW:indP2+ii+NumW);
        t2(ii+1,1:NumDEnt-NumW)=tiempo(indP1+ii+NumW:indP2+ii+NumW);
    end
    net=newind(P,T);%se crea la red neuronal lineal y se entrena
    indpred1=indP2+Numhp;
    indpred2=indpred1+NumW-1;
    indpred=(indpred1:indpred2);
    %P1=[ph(indpred);MareaArm(indpred);Resid(indpred)];
    %P1=[ph(indpred);MareaArm(indpred);Resid(indpred);U(indpred);V(indpred)];
    %P1=[MareaArm(indpred);Resid(indpred);U(indpred);V(indpred)];
    P1=[MareaArm(indpred);Resid(indpred)];%se crea los ultimos datos de entrada
    a = sim(net,P1);%se ingresan los ultimos datos y se obtiene la prediccion "a"
    tp=(indpred2+1:indpred2+Numhp);%tiempo de la prediccion
    R=[R;a];%vector de salida
%    tr=[tr;tp];

    %e=T-a
    %plot(tp,a,'r')
end
else
    'No es posible realizar los calculos, el numero de datos es menor de lo requerido'
end
tr1=(tiempo(end)-Numdp1*24:tiempo(end));
tr2=(tiempo(end):tiempo(end)+Numhp-1);
trp=tiempo((end)-Numdp1*24:(end)-1);
R1=R(1:(end)-Numhp);
R2=R(end-Numhp+1:(end))
tr1=(fi+tr1)/24;tr2=(fi+tr2)/24
trp=(fi+trp)/24;
MrealHs=MrealH((end-Numdp1*24):(end))
MareaArms=MareaArm((end-Numdp1*24):(end))
%tiempo2=(fi+tiempo)/24;
%tiempstr=datestr(tiempo2);
%*****
%se imprime la prediccion
    
```

```
figure
plot(tr1, MrealHs,'-o',tr1, MareaArms,'g -',tr2,R2,'- m *',trp,R1,'r -+')
title('PREDICCIÓN DE MAREA')
xlabel('Tiempo (Dias)')
ylabel('Altura (m)')
legend('Real','Armonico','Pred Adelantada')
dateaxis('X',1)
grid
```