



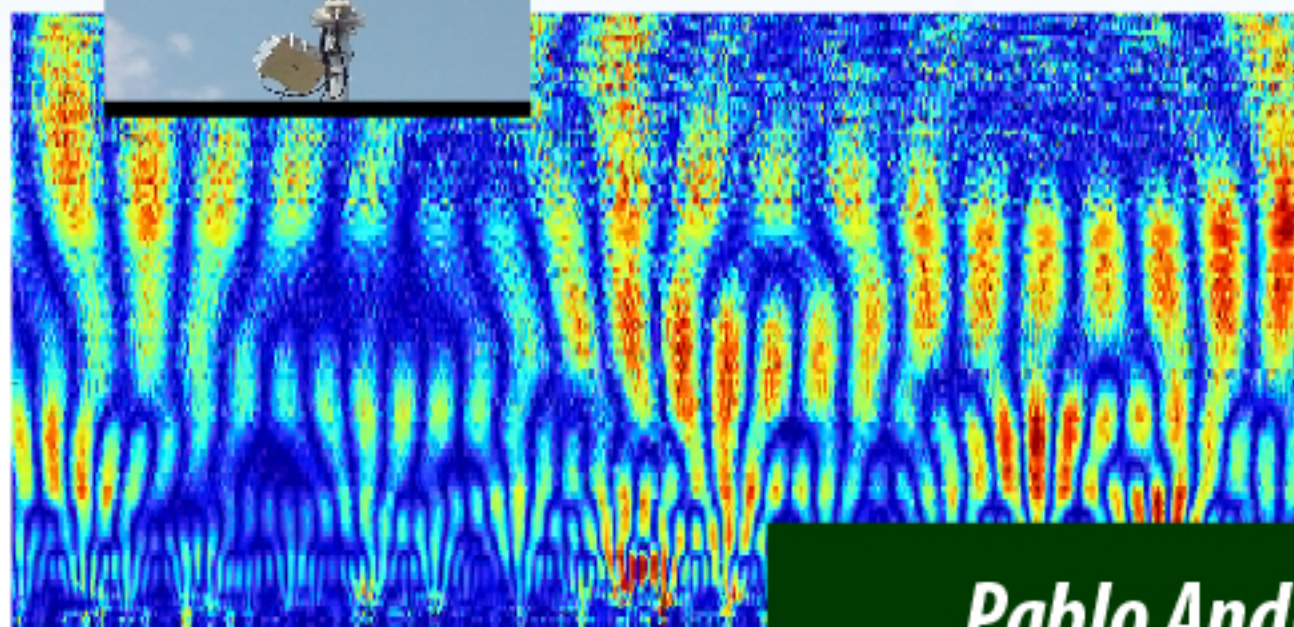
Universidad Autónoma de Baja California
Instituto de Ingeniería



Programa de Maestría y Doctorado en Ciencias e Ingeniería

*Tesis para obtener el título de:
Doctorado en Ciencias*

Pronóstico de la Precipitación Pluvial en una Estación Climatológica
en el Noroeste del Estado de Baja California Utilizando Transformada
Wavelet, Redes Neuronales Artificiales y Neurodifusas.



Presenta:

Pablo Andrés Rousseau Figueroa

Director de tesis: **Dr. Jorge Ramírez Hernández**

Mexicali B.C., Febrero de 2013

Universidad Autónoma de Baja California Instituto de Ingeniería

**Pronóstico de la Precipitación Pluvial en una Estación Climatológica en el
Noroeste del Estado de Baja California Utilizando Transformada Wavelet,
Redes Neuronales Artificiales y Neurodifusas.**

Tesis

para obtener el título de DOCTOR en CIENCIAS que presenta

Pablo Andrés Rousseau Figueroa

Y aprobada por el siguiente comité Tutorial

**Dr. Jorge Ramírez Hernández
Presidente**

**Dr. Fortunato Espinoza Barreras
Sinodal**

**Dr. Rafael Villa Angulo
Sinodal**

**Dra. Michelle Hallack Alegría
Sinodal Suplente**

**Dr. Octavio Lázaro Mancilla
Secretario**

Febrero de 2013

Dedicatoria

A mis padres

Pablo y Teresa, por el apoyo y cariño incondicional que siempre me han brindado, además por contribuir a la realización de mis sueños ya que siempre me dejaron volar con mis propias alas. Muchas gracias

A mi esposa

María Guadalupe, por su amor, apoyo, comprensión, cariño, sobre todo porque eres la parte más importante en mi existencia.

A mis hijos

Pablo Bryan, Andrés Antuann, Guadalupe Alitzel y Aislany Arhlyn, mis cuatro grandes amores, por su amor, cariño y hacerme sentir su presencia, aún cuando en ocasiones he estado lejos.

A mis hermanas

Tere y Judith, por su apoyo incondicional, su cariño, ¡las quiero mucho!.

A mis tíos

Carlos Eugenio † e Higinio Alfredo †, mis grandes genios, ¡puro corazón!, ¡siempre los llevaré en el alma!.

A dios

Por ser un gran amigo y estar conmigo siempre ...

A toda mi familia con cariño y respeto ...

**Sinceramente
Pablo**

Agradecimientos

Debo hacer patente mi más sincero agradecimiento a las siguientes personas e instituciones por el apoyo brindado durante el desarrollo de este trabajo de tesis doctoral.

Al director de esta tesis, **Dr. Jorge Ramírez Hernández**, le agradezco infinitamente sus consejos y comentarios, sobre todo por creer en este proyecto y tenerle paciencia, además por su constante apoyo y disposición en las diferentes etapas de este trabajo, que gracias a sus valiosos conocimientos en el área de los recursos hídricos, su experiencia en investigación impulsaron exitosamente esta investigación, ¡uno de los anhelos más grandes de mi vida!. Gracias por su Amistad.

Al **Dr. Fortunato Espinoza Barreras**, que siempre me ha brindado su amistad, además por mostrarme el camino sobre estas nuevas técnicas que se aplican a la ingeniería hidráulica, sobre todo por sus valiosos consejos y comentarios que me llevaron por la senda del éxito. Muchas gracias Fortunato.

Al **Dr. Rafael Villa Angulo**, que es toda una institución en el campo de la inteligencia artificial, además de brindarme su amistad desde un inicio, me facilitó todos sus conocimientos y experiencias que impulsaron y alentaron mi formación doctoral. Siempre le estaré agradecido.

Al **Dr. Octavio Lázaro Mancilla**, por la atención prestada y todos los meritorios comentarios que realizó durante esta investigación, permitieron encontrar hallazgos significativos que mejoraron este proyecto de tesis. Mi profundo sentimiento de gratitud.

A la **Dra. Michelle Hallack Alegría**, quien siempre mostró interés en esta investigación y me dio el ejemplo para no declinar este proyecto.

Al **Dr. Rafael Hernández Walls**, por sus valiosos comentarios y asesoría en el campo del análisis de señales.

A mis **profesores**, por su sabiduría, consejos y definitivamente persistencia para terminar este trabajo.

Al coordinador del MYDCI: **Dr. Néstor Santillán Soto**, por su profesionalismo y apoyo brindado. Muchas gracias.

Al ex-rector **Dr. Gabriel Estrella Valenzuela**, que durante su gestión me motivo para desarrollar y culminar esta nueva etapa en mi vida. Muchas gracias por su apoyo.

A nuestra alma mater: **Universidad Autónoma de Baja California**, por darme la oportunidad de desarrollarme académica, humana y profesionalmente.

A mis compañeros de la FIAD: **Everardo Inzunza, Sergio Infante, Joel Hernández, Jesús Olguín, Gustavo Morales, Jorge Limón, Efrén García, Yolanda Báez, Juracy Soares, Rubén Campos, Ricardo Sánchez, Felipe Ricalde †, Álvaro Hernández, Miguel Mario Juarez, Odin Meling, Manuel Jiménez, Diego Tlapa, Julián Aguilar, Herminio Estrada, Jesús Salinas, Genaro Silvera, Cesar Obregón. Juan Pablo Torres, Christian Navarro, Santiago Álvarez, Edgar Arroyo, Claudia Camargo, José Luis Javier Sánchez, Héctor Ayón, Luisa Reyes, Sara López, Eliud Gil, Ana Rivera,** ¡Gracias amigos! por alentarme, apoyarme, aconsejarme, sobre todo brindarme su amistad.

Asimismo estaré eternamente agradecido con todas las personas que de una u otra manera han estado cerca de mí en esta etapa de mi vida.

Sinceramente

M. en Ing. Pablo Andrés Rousseau Figueroa

Febrero de 2013

Índice		Página
Resumen		1
Abstract		3
1. Introducción		5
1.1. Antecedentes socioeconómicos		5
1.2. Región Hidrológica 01		8
1.2.1. Precipitación, escurrimientos y recarga		8
1.2.2. Infraestructura		10
1.3. Hidroeconomía		11
1.3.1 Contradicciones		12
1.4. Información Hidroclimatológica		13
1.5. Objetivos		15
1.5.1 Objetivo General		15
1.5.2 Objetivos Específicos		15
1.6. Justificación		16
1.6.1. Justificación Técnica		16
1.6.2. Justificación Económica		16
1.6.3. Justificación Social		18
1.6.4. Justificación Ambiental		18
2. Estado Actual del Conocimiento		19
2.1. Introducción		19
2.1.1. Estudios previos		20
2.1.1.1. Estudios previos ANN		20
2.1.1.2. Estudios previos DWT		22
2.1.1.3. Estudios previos Modelos Híbridos		28
2.2. Marco teórico		32
2.2.1. Transformada Wavelet		32
2.2.1.1. Transformada Wavelet Continua		35
2.2.1.2. Transformada Wavelet Discreta		37

	Página
2.2.1.2.1 Máxima Superposición	41
2.2.1.2.1. El algoritmo de Mallat	42
2.2.1.2.2. El algoritmo 'à trous'	44
2.2.1.2.3. El algoritmo <i>MODWT</i>	45
2.2.2. Redes Neuronales Artificiales	45
2.2.2.1. Entrenamiento de la red	50
2.2.2.2. Algoritmo de Levenberg Marquardt	51
2.2.2.3. El diseño de una <i>ANN</i>	53
2.2.2.4. Agrupamiento de los datos	53
2.2.2.5. Validación de un modelo	55
2.2.3. <i>ANFIS</i>	55
2.2.3. Indicadores caóticos	57
2.2.3. Exponente de Hurst	57
2.2.3. Exponente de Lyapunov	60
3. Métodos	65
3.1. Introducción	65
3.2. Algoritmos híbridos desarrollados	65
3.2.1. Descomposición con <i>DWT</i>	66
3.2.2. Método para el pronóstico	75
4. Resultados y discusiones	80
4.1. Resultados	80
4.2. Discusiones	98
Conclusiones	104
Bibliografía	108
Apéndice A	109
Apéndice B	122
Apéndice C	125

Índice de Tablas

	Página
Tabla 1.1 Categorías de vulnerabilidad socioambiental por diferentes causas relacionadas con el agua. Esta clasificación es la aplicada a Baja California.	6
Tabla 4.1 Información relativa a los datos estadísticos e indicadores caóticos del registro de precipitación de la estación Ensenada.	88
Tabla 4.2 Resultados del modelo WN del primer enfoque.	91
Tabla 4.3 Coeficiente de correlación de la señal con las descomposiciones del nivel 1 a 9.	95
Tabla 4.4 Resultados del modelo WN del segundo enfoque.	96
Tabla A.1 Relación entre los dBz y la intensidad de la lluvia en mm/hr . El valor de 20 dBz es cuando aproximadamente inicia la precipitación.	119
Tabla A.2 Relación entre los tipos de lluvia y la f_r fórmula de reflectividad en función de la intensidad de la lluvia en mm/h .	120
Tabla C.1. Relación de estaciones climatológicas, hidrométricas y RADAR.	125

Índice de Figuras

	Página
Figura 1.1. Crecimiento de la población en el noroeste del estado de Baja California, (INEGI, 2011).	12
Figura 2.1. Funciones wavelet madre. a) Daubechies, b) Sombrero Mexicano, c) Haar y d) Morlet.	34
Figura 2.2. Esquema de un Escalograma.	37
Figura 2.3. Escalograma de una serie de tiempo de la estación Ensenada correspondiente a datos de lluvia	38
Figura 2.4. Representación del algoritmo de descomposición wavelet de Mallat.	43
Figura 2.5. Representación del algoritmo de descomposición wavelet “à trous”	44
Figura 2.6. Configuración de una ANN alimentada hacia adelante con una entrada y dos capas.	48
Figura 2.7. ANN alimentada hacia adelante con entrenamiento de retropropagación de los errores.	49
Figura 2.8. a) Modelo difuso de primer orden tipo Sugeno, con dos estradas y dos reglas. b) Arquitectura equivalente de ANFIS.	56
Figura 2.9. Atractor de Lorenz, con $a = 10$ número de Prandtl, $b = 28$ número de Rayleigh y $c = 8/3$, $dt = 0.01$. Edward Lorenz (1963), la forma del atractor pudo haber inspirado el nombre del <i>efecto mariposa</i> en esta teoría, aunque en la literatura revisada nadie lo confirma.	61
Figura 3.1. Esquema del filtrado de la señal. a) Descomposición, b) Reconstrucción.	68
Figura 3.2. Filtrado de descomposición de la aproximación con el algoritmo de Mallat.	69

	Página
Figura 3.3. Filtrado de descomposición de los detalles con el algoritmo de Mallat.	70
Figura 3.4. Filtrado de la señal en reconstrucción por el algoritmo de Mallat.	71
Figura 3.5. Filtrado de descomposición de la aproximación con el algoritmo de <i>MODWT</i> .	72
Figura 3.6. Filtrado de descomposición de los detalles con el algoritmo de <i>MODWT</i> .	73
Figura 3.7. Filtrado de la señal en reconstrucción por el algoritmo de <i>MODWT</i> .	74
Figura 3.8. Esquema del Primer Enfoque. Se descompone la señal $S(t)$ mediante la <i>DWT</i> , los componentes de detalle $S_{D1}(t)$, $S_{D2}(t), \dots, S_{Dj}(t)$; la última aproximación $S_{Aj}(t)$; y la señal original $S(t)$ con diferentes valores de antelación son utilizados como entradas a la ANN o ANFIS, y mediante los pesos W se encuentra el siguiente valor de la serie $S(t+1)$ pronosticado.	77
Figura 3.9. Esquema del Segundo Enfoque. Se descompone la señal $S(t)$ mediante la <i>DWT</i> , después se eliminan sistemáticamente los coeficientes de detalle, se reconstruye la señal mediante la <i>DWT</i> inversa, de esta manera se encuentra una señal nueva más suave $S_{NUEVA}(t)$ que es la que se utiliza como entrada con diferentes valores de antelación a los algoritmos de ANN o ANFIS, y mediante los pesos WS_{NUEVOS} se encuentra el siguiente valor de la serie $S(t+1)$ pronosticado.	78
Figura 4.1 Localización de la ciudad de Ensenada donde se ubica la estación 016 con el mismo nombre.	81

	Página	
Figura 4.2	Distribución de la precipitación en mm en la zona costa de la RH01 y localización de las estaciones climatológicas con información suficiente (figura proporcionada por la CONAGUA).	82
Figura 4.3	Escalograma hasta el nivel 100 de los 754 meses de precipitación y serie de tiempo correspondiente a la estación climatológica Ensenada.	83
Figura 4.4	Escalograma correspondiente a una ventana de la figura 4.3, entre las escalas 38 y 80 de los meses 511 al 754 y serie de tiempo de precipitación correspondiente al mismo periodo para la estación climatológica Ensenada.	86
Figura 4.5	Escalograma de la estación Ensenada, para lluvias mensuales de 1948 a 2004, o sea 754 valores. Se presenta una lluvia característica en la escala nueve aproximadamente entre los años 350 y 390.	87
Figura 4.6	Serie de tiempo de precipitación mensual de la estación Ensenada de Mayo de 1948 a Febrero de 2011.	89
Figura 4.7	Descomposiciones de la serie de Ensenada con el algoritmo de MODWT hasta el nivel 3.	90
Figura 4.8	Resultados de entrenamiento, validación y pronóstico utilizando el segundo enfoque con el algoritmo Mallat- <i>FFBP</i> .	92
Figura 4.9	Resultados con el método <i>ANFIS</i> autónomo.	93
Figura 4.10	Resultados del pronóstico de la función seno con tres valores de antelación empleando ANN para tres grupos de datos: entrenamiento, validación y pronóstico.	99
Figura 4.11	Resultados del pronóstico de la función seno con dos valores de antelación empleando ANN para tres grupos de datos: entrenamiento, validación y pronóstico.	100

	Página
Figura 4.12 Resultados del pronóstico de la función seno con un valor de antelación empleando ANN para tres grupos de datos: entrenamiento, validación y pronóstico.	101
Figura 4.13 Resultados del pronóstico de la función seno con dos valores de antelación empleando ANFIS para tres grupos de datos: entrenamiento, validación y pronóstico.	101
Figura 4.14 Resultados del pronóstico de la función seno con un valor de antelación empleando ANFIS para tres grupos de datos: entrenamiento, validación y pronóstico.	102
Figura A.1 Radares Doppler en EUA modelo WSR-88D, que administra el NWS y el Departamento de Defensa de los EUA.	116
Figura A.2 RADAR Doppler ubicado en el condado de san Diego, EUA. La imagen es obtenida el 26 de Noviembre del 2008 a las 9 horas con 17 minutos y presenta una advertencia de precipitación.	118
Figura A.3 Implementación del programa WCT 2.5.0 para la información del RADAR Doppler ubicado en el condado de san Diego, EUA. En la imagen (04/30/1997, 02:25:37 horas) se observa ruido hasta el momento desconocido.	120
Figura A.4 Implementación del programa WCT 2.5.0 para la información del RADAR Doppler ubicado en el condado de san Diego, EUA. En la imagen (04/30/1997, 07:09:55 horas) se observa ruido hasta el momento desconocido.	121

Índice de Abreviaturas

Abreviatura	Significado	Meaning
ANFIS		Adaptive-Network-Based Fuzzy Interface System
ANN	Redes Neuronales Artificiales	Artificial Neural Networks
ARIMA	Autorregresivos Integrados de Media Móvil	
CPN		Counterpropagation Network
CWT	Transformada Wavelet Continua	Continuous Wavelet Transform
DCWT		Discrete Continuous Wavelet Transform
Db4	Daubechies de orden cuatro	
DWT	Transformada Wavelet Discreta	Discrete Wavelet Transform
EUA	Estados Unidos de América	
FFBP		Feed Forward Back Propagation
FGN		Fractional Gaussian Noise
FIS	Sistema de Interface Difuso	Fuzzy Interface System
GRNN		Generalized Regression Neural Network
HP	Filtro pasa-altas	
LM		Levenberg-Marquardt
LP	Filtro pasa-bajas	
MF	Función de Membresía	
MODWT	Transformada Wavelet Discreta de Máxima	Maximal Overlap Discrete Wavelet Transform

	Superposición	
Abreviatura	Significado	Meaning
MSE		Mean Square Error
NWS		National Weather Service
PIB	Producto Interno Bruto	
R²	Coeficiente de determinación	
RADAR		Ratio Detection And Ranging
RH01	Región Hidrológica 01	
RLM	Regresión Lineal Múltiple	
RMSE		Root Mean Square Error
SEB	Sin Efecto de Borde	
SVMs		Support Vector Machines
TLRN		Time Lagged Recurrent Network
VCP		Volume Coverage Patterns
WCT		Weather and Climate Toolkit
WM	Wavelet Madre	
WMA	Análisis Wavelet Multiresolución	Wavelet Multiresolution Analysis
WN		Wavelet Neuronal
WT	Transformada Wavelet	Wavelet Transform

Resumen

El agua siempre ha jugado un papel central en la sociedad humana. A lo largo de la historia una prioridad constante del ser humano ha sido el aprovechamiento de todo el potencial de sus recursos hídricos, por medio del suministro adecuado y la disminución de sus efectos destructivos, de tal manera que pueda impulsar el crecimiento. México es un país en vías de desarrollo, su crecimiento económico no ha tomado en cuenta plenamente las señales de escasez del agua. En el estado de Baja California, México, existe vulnerabilidad socioambiental por la disponibilidad del agua clasificada en su mayoría como de la más severa en el país. En este estado se ubica la Región Hidrológica 01 Baja California Noroeste (Ensenada) en la vertiente del Pacífico adoptada como la zona de estudio en este trabajo. En esta Región la principal fuente de abasto es el agua subterránea y la recarga de sus acuíferos depende de los escurrimientos de la precipitación pluvial y el deshielo. La información hidroclimatológica proviene de tres fuentes: i) las estaciones climatológicas administradas por la Comisión Nacional del Agua; ii) las estaciones automáticas propiedad de la Secretaría de Fomento Agropecuario y iii) los registros del *National Weather Service* de los Estados Unidos fuera de la Región. La carencia, ausencia o limitación de la información hidroclimatológica de calidad así como el análisis tradicional realizado imposibilita un mejor conocimiento del fenómeno y por lo tanto, la construcción de proyecciones confiables de su evolución futura. Por esta razón, en este trabajo se propone la aplicación de tecnologías ubicadas en la frontera del conocimiento, a dichos registros, para hacer pronósticos que incidan en el mejor aprovechamiento del recurso.

Para la implementación del modelo se estudió la información disponible y se decidió utilizar la información de la estación climatológica ubicada en la presa Emilio López Zamora en la ciudad de Ensenada por su calidad de información, ubicación, longitud de registro y el número de datos faltantes. Se hizo una revisión profunda de las metodologías híbridas utilizadas para el análisis de series de tiempo climatológicas e hidrológicas que toman en cuenta las características no-estacionales y no-deterministas que en este tipo de series

están presentes, con el propósito de utilizar las más adecuadas y evaluar su aplicación y validez. Con esta información se alimentan algoritmos de análisis de señales y de pronóstico, asimismo modelos híbridos Wavelet Neuronal o Wavelet Neurodifusos para pronosticar series de tiempo mensuales de lámina de precipitación con un mes de anticipación. En la primera parte del estudio que se realiza para identificar el tipo de señal que se analizará, se utiliza el *Wavelet Multiresolution Analysis* con el propósito de encontrar estructuras cuasi-similares, además se emplean indicadores caóticos para el análisis de las series como lo son los exponentes de Hurst y Lyapunov. La segunda parte del estudio, donde se efectúa la implementación de los algoritmos híbridos de pronóstico, combina cuatro métodos, i) *Discrete Wavelet Transform* con el algoritmo de Mallat, ii) *Maximal Overlap Discrete Wavelet Transform*, iii) *Feed Forward Back Propagation* y, iv) *Adaptive-Network-based Fuzzy Interfase System*. Se utilizan dos enfoques de preprocesamiento utilizados actualmente en la literatura para pronosticar series climáticas de variables hidrológicas. En el primer enfoque se emplean cuatro métodos para realizar la convolución de la transformada y se discute su relación con el fenómeno del efecto de borde. Los resultados demuestran que el modelo híbrido utilizado influye significativamente para mejorar el entrenamiento de la red con fines de predicción, debido a que estrictamente hablando los coeficientes wavelet contienen la información futura de los valores de la serie, sin embargo para la etapa de pronóstico se demuestra que es altamente significativo el método que se utilice para realizar el filtrado. En el segundo enfoque se encuentra que la serie de tiempo se tiene que reconstruir con coeficientes wavelet de escalas que corresponden a un periodo de cinco años aproximadamente y se demuestra que existe una significativa componente de ruido wavelet en la señal transformada, además se discute el efecto de borde debido al suavizado.

Abstract

Water has always played a central role in human society. Throughout history a constant priority for the human being has been harnessing the full potential of their water resources through adequate supply and decreasing their destructive effects, in such a way that can growth can be boosted. Mexico is a developing country, its economic growth has not fully taken into account the water scarcity signals. In Baja California, Mexico, there exists socioenvironmental vulnerability caused by water availability, mostly classified as the most severe in the country. In this state, the Hydrological Region 01 Northwest Baja California (Ensenada), is located, in the Pacific watershed. In this region, the main source of supply is underground water the aquifers' refill relies on rainfall and snowmelt runoff . This hydrologic region is the study area of this paper and has two key characteristics: first, the water infrastructure for the use of water resources is scarce or outdated; second, the contradictions of the hydrological cycle is fully implemented.

Hydroclimatological information in Hydrological Region 01 comes from three sources: i) climatological stations managed by the National Water Commission, ii) by the automatic stations owned by the Ministry of Agricultural Development and iii) the records of the U.S. National Weather Service . The lack, absence or limitation of quality hydroclimatological information precludes from a better understanding of reality and the construction of reliable projections for future developments. For this reason, in this work we propose applying, to such records, technologies at the frontier of knowledge to perform forecasts that can be used for a better harnessing of the resource.

This information is fed to signal analysis and forecasting algorithms, as well as Wavelet Neural or Wavelet Neurofuzzy hybrid models, to perform the forecasting of monthly time series of precipitation depth one month ahead. To implement the model, we studied the information available and decided to use the information from the weather station located at the Emilio López Zamora dam, in the city of Ensenada in northwestern Baja California, México. In the first part of the study that is performed to identify the type of signal being analyzed, we used the

Multiresolution Wavelet Analysis to find quasi-similar structures, as well as chaotic indicators, such as Hurst and Lyapunov exponents, to analyze the series. The second part of the study, where are implemented hybrid forecasting algorithms, combines four methods, i) Discrete Wavelet Transform with Mallat algorithm, ii) Maximal Overlap Discrete Wavelet Transform, iii) Feed Forward Back Propagation network and, iv) Adaptive-Network-based Fuzzy Interface System. Two preprocessing approaches are used currently in the literature to predict climate series hydrological variables. In the first approach used four methods to perform the convolution of the transform and discuss their relationship with the edge effect phenomenon. The results show that the hybrid model used significantly improves the network training with prediction purposes because, strictly speaking, wavelet coefficients contain the information of future values in the time series. However for the prediction stage, it is shown that the method to perform filtering is highly significant. In the second approach, it is found that the time series has to reconstruct scale wavelet coefficients corresponding to a period of about five years and it is demonstrated that there is a significant wavelet noise component in the signal transform. Furthermore, it discusses the effect edge due to smoothing.

Capítulo I

1. Introducción

A lo largo de la historia ha existido un fuerte vínculo entre el crecimiento económico y el desarrollo de los recursos hídricos (UNESCO, 2009). El agua es un recurso estratégico y de seguridad nacional (CONAGUA, 2003), siempre ha jugado un papel central en la sociedad humana debido a que es considerada un líquido vital y fundamental para cada ser vivo, además es esencial para gran parte de los procesos productivos. El agua desde el punto de vista socioeconómico es origen de crecimiento y riqueza, en contraparte es motivo de recesión y pobreza, debido a que es motor a través del ciclo hidrológico del abastecimiento de agua para la agricultura, ganadería, sociedad, industria, saneamiento, ecosistemas, etc. Sin embargo produce destrucción ya que es causante de catástrofes como: inundaciones, sequías, erosión, desertificación, falla de estructuras, anegamiento y deslizamiento de tierra, epidemias, contaminación, enfermedades, conflictos y guerras.

La concentración de la población y la actividad económica han creado zonas de alta escasez, no sólo en las regiones de baja precipitación pluvial sino también en zonas donde eso no se percibía como un problema al comenzar el crecimiento urbano o el establecimiento de agricultura de riego (Sainz y Becerra, 2012).

1.1. Antecedentes socioeconómicos

En el año 2025 más de 3 mil millones de personas en el mundo podrían estar viviendo en países que sufren estrés de agua, y 14 países pasarán de padecer estrés de agua a sufrir escasez de este recurso, esta última puede ser física, económica e institucional, y como el agua misma, puede fluctuar en el tiempo y en el espacio (ONU, 2006; OCDE, 2011). Por ejemplo, las predicciones para el 2025 resaltan a Baja California y a Chihuahua como los estados más vulnerables para la migración de sus habitantes por escasez de agua debido a sus altas temperaturas, poca precipitación, alto consumo de agua y energía (RUSI, 2011).

De acuerdo al Instituto Nacional de Ecología (INE, 2002) en Baja California existe vulnerabilidad socioambiental por el agua. Esta vulnerabilidad en este Estado es clasificada como de la más severas en el país en las categorías mostradas en la tabla 1.1. De acuerdo a ONU (2006) la sobreexplotación de acuíferos en Baja California es severa.

Tabla 1.1 Categorías de vulnerabilidad socioambiental por diferentes causas relacionadas con el agua. Esta clasificación es la aplicada a Baja California.

vulnerabilidad	causa
crítica	disponibilidad del agua, presión o estrés hídrico
climática alta	sequía e inundación
alta	disponibilidad del agua
alta	contaminación del agua
alta	disponibilidad del agua urbana (solo Tijuana)
media	explotación de más, del 10 al 19% de volumen de agua de acuíferos
media	agrícola
baja	se considera con baja biodiversidad en riesgo por el agua
muy baja	marginación social debido a que se consideran los servicios del agua, además de otros cuatro factores

En el documento del IV Foro Mundial del Agua (Banco Mundial y IV Foro Mundial del Agua, 2006) se hace una comparación de los recursos hídricos existentes entre los países industrializados, las economías intermedias y los países en vías de desarrollo y de acuerdo a este documento las causas de la diferencia se deben en su mayoría a sus condiciones climáticas, aunque existen excepciones.

En *economías menos desarrolladas* el clima estacional, la variabilidad y/o las lluvias extremas son con frecuencia muy marcados, mientras que la capacidad, instituciones e infraestructura necesarias para manejar y mitigar estos desafíos potencialmente importantes resultan generalmente inadecuadas.

Los eventos hidrológicos catastróficos tales como sequías e inundaciones pueden producir impactos sociales y económicos dramáticos con disminución del PIB anual que frecuentemente sobrepasa el 10% y ocasionan la pérdida de vidas. Lo que resulta menos aparente es que, como consecuencia de las expectativas muy generalizadas de que estas catástrofes no mitigadas serán recurrentes, el comportamiento contrario al riesgo y la falta de incentivos para la inversión se vuelven penetrantes. Ese tipo de comportamiento puede seriamente socavar las inversiones de toda la economía y con ello el crecimiento aun en años con lluvias abundantes. Dentro del nivel sectorial, observamos muchas consecuencias derivadas de una deficiente gestión de los recursos hídricos, tales como una producción de alimentos impredecible debida a la variabilidad climática, a los efectos en la salud de un abastecimiento insuficiente de agua y un saneamiento inadecuado, abastecimiento poco confiable de electricidad, y un clima pobre de inversión debido a una infraestructura de transporte y energía afectada por el agua. En muchos de los países más pobres del mundo, la variedad climática es alta, las inversiones relacionadas con el sector agua son relativamente limitadas y con frecuencia se presenta una fuerte correlación aparente entre la hidrología y la variación del PIB. Esto es particularmente válido en economías cuya agricultura depende de las lluvias y tal parece que éste es un fenómeno global significativo. Donde el comportamiento de la economía esté íntimamente ligado a la lluvia y a los escurrimientos naturales, el crecimiento se vuelve *rehén de la hidrología* (Banco Mundial y IV Foro Mundial del Agua, 2006).

En México existe un estado joven y en pleno desarrollo, Baja California, que cuenta con riquezas naturales, formación de recursos humanos de alto nivel, además en corto tiempo ha logrado un avance técnico-industrial y se le visualiza un gran futuro. El crecimiento económico de acuerdo al Producto Interno Bruto

(PIB) con respecto al nacional se ha mantenido aproximadamente constante en el periodo 2005-2009, pero la tasa de crecimiento del PIB actualmente está en decremento (SEDECO, 2012), además Baja California en el año 2009 contribuyó con el 2.8% del nacional ubicándose en el lugar no. 13 (INEGI, 2012). Sin embargo, para sus aspiraciones de desarrollo existe un grave problema a considerar y se trata de la escasez del agua en la mayor parte de su territorio (CONAGUA, 2012). Paradójicamente la región presenta inundaciones severas en los periodos de lluvia extremos causando además de los destrozos que, el agua tan necesaria, simplemente escurra al mar.

1.2. Región Hidrológica 01

La Comisión Nacional del Agua (CONAGUA, 2003) ubica a la península de Baja California en la Región No. I. Esta región se subdivide en siete regiones hidrológicas (RH) y esta tesis se refiere a la denominada RH01 Baja California Noroeste (Ensenada) y se ubica en la porción Centro-Noroeste del Estado en la vertiente del Pacífico aproximadamente entre los paralelos 29°27'41" y 32°47'31" de latitud norte con una superficie aproximada de 26,285 km², tiene clima seco templado (INEGI, 1995; Rousseau, 2001), específicamente clima Mediterráneo BSka; lluvias predominantes en el invierno en la costa y templado Cs; en las partes altas como la Sierra San Pedro Mártir (SEMARNAT, 2012). En esta región hidrológica la precipitación se presenta en los meses de noviembre a marzo y la media anual varía de 200 mm en la partes bajas costeras a 400 mm en las partes altas que corresponden a las sierras (INEGI, 1995).

1.2.1. Precipitación, escurrimientos y recarga

En la RH01 la precipitación produce una parte de disponibilidad de agua en la zona de 265.01 hm³año⁻¹ además de la importación a la zona norte de la región 126.1 hm³año⁻¹ de agua proveniente del acuífero de la mesa arenosa del delta del Río Colorado (CONAGUA, 2003). La precipitación se manifiesta por varias corrientes efímeras (no existen escurrimientos superficiales permanentes) que sólo conducen agua de eventos de lluvia o deshielo de la nieve lo que repercute

en el aprovechamiento del agua ya sea superficial o subterránea, limitando la recarga que reciben los acuíferos (SEMARNAT, 2012). En la RH01 la evaporación es elevada, el promedio en los vasos de las presas es de 1500 mm (CEA, 2008). Además las condiciones geológicas son adversas, debido a que la mayoría de las unidades de roca permiten que el agua fluya libremente debido a las elevadas pendientes por esa condición pétreo, y sólo una mínima parte de esos escurrimientos llegan a los acuíferos, por lo tanto, la distribución de los mantos acuíferos es heterogénea y se localiza en áreas relativamente pequeñas (IMIP, 2010).

En la RH01 los escurrimientos totales son de $342 \text{ hm}^3\text{año}^{-1}$ y el escurrimiento al mar es de $64 \text{ hm}^3\text{año}^{-1}$ (CONAGUA, 2003; SEMARNAT, 2012). De acuerdo al área las cuencas más importantes son los arroyos Tijuana con una superficie de $4,567 \text{ km}^2$, y le continúan las cuencas de los arroyos El Rosario, Guadalupe, Cañón de San Fernando, Salado, San Vicente, San Simón, San Rafael, Santo Domingo, San Telmo, San Carlos, Las Ánimas, Santo Tomás, San Vicente, El Socorro, San Antonio, Ensenada, El Descanso y El Gallo (CONAGUA, 1995). Las corrientes son pequeñas y paralelas, existe una distancia aproximada de 100 km desde las partes altas hasta su desembocadura con el Océano Pacífico, aunque el más grande es el arroyo Tijuana con 195 km de longitud aproximadamente. Desde el punto de vista del escurrimiento, la cuenca del arroyo Tijuana es la más importante $74 \text{ hm}^3\text{año}^{-1}$, seguida por las cuencas de los arroyos Guadalupe $68 \text{ hm}^3\text{año}^{-1}$, Santo Domingo $48 \text{ hm}^3\text{año}^{-1}$ y San Rafael $40 \text{ hm}^3\text{año}^{-1}$ (SEMARNAT, 2012).

En la región en estudio la recarga de acuíferos es un elemento fundamental para la disponibilidad de agua, existen 25 de ellos con una recarga total de $212 \text{ hm}^3\text{año}^{-1}$ y un volumen de extracción de $249 \text{ hm}^3\text{año}^{-1}$, o sea existe una sobreexplotación $37 \text{ hm}^3\text{año}^{-1}$ (SEMARNAT, 2012). El de mayor recarga es el arroyo Guadalupe $61.04 \text{ hm}^3\text{año}^{-1}$, seguido por los arroyos Tijuana $34.60 \text{ hm}^3\text{año}^{-1}$, Salado $30.35 \text{ hm}^3\text{año}^{-1}$, Las Animas $20.80 \text{ hm}^3\text{año}^{-1}$, Santo Domingo $19.52 \text{ hm}^3\text{año}^{-1}$, La Escopeta/Nueva York $19.1 \text{ hm}^3\text{año}^{-1}$ y San Simón $13.5 \text{ hm}^3\text{año}^{-1}$ (CONAGUA, 2003). Los acuíferos de la RH01 se ubican sobre los

depósitos aluviales recientes, son en general de tipo libre, detríticos y con poca potencia. Descansan sobre el basamento rocoso que conforma el batolito peninsular. Su principal fuente de recarga son las corrientes superficiales. La mayoría de los pozos se ubican sobre los lechos de las corrientes superficiales y en los rellenos sedimentarios de valles intermontañosos, como el Guadalupe y Ojos Negros. Como en muchas otras partes del mundo el mayor porcentaje de agua es utilizado por las actividades agrícolas seguido del abastecimiento público urbano. Los principales centros de población se encuentran en las costas utilizando agua de los acuíferos costeros y en algunos casos como el de la ciudad de Ensenada trasvasan agua de acuíferos intermontañosos (Valle de Guadalupe) para satisfacer su demanda. Esta enorme demanda de agua ha dado lugar a una sobreexplotación de los acuíferos, algunos de ellos se encuentran actualmente en condiciones críticas aumentando progresivamente la entrada de agua salina desde el mar con el consiguiente deterioro de su calidad. El otro centro de población con mayor cantidad de habitantes del Estado es la ciudad de Tijuana cuya demanda requiere ser satisfecha principalmente de tres fuentes de agua: su propio acuífero, el recurso trasvasado de la cuenca del Río Colorado y el ocasionalmente almacenado en la presa Abelardo L. Rodríguez en los periodos de lluvia extrema.

1.2.2. Infraestructura

Enormes esfuerzos de construcción de infraestructura para la conducción y el abastecimiento de agua se han realizado en la región. El trasvase de agua a las cuencas deficitarias a requerido la construcción de diversos acueductos. Entre ellos, los acueductos desde el Río Colorado-Tijuana aporta un gasto equivalente a $5.33 \text{ m}^3\text{s}^{-1}$. El acueducto de Las Auras-Tecate con un gasto nominal de $0.35 \text{ m}^3\text{s}^{-1}$, y el La Misión-Tijuana con $0.25 \text{ m}^3\text{s}^{-1}$, varían el volumen conducido dependiendo de la demanda en Playas de Rosarito (CEA, 2003; CEA, 2008, SEMARNAT, 2012). Otros acueductos relevantes de la zona son El Guadalupe de $0.16 \text{ m}^3\text{s}^{-1}$, La Misión de $0.25 \text{ m}^3\text{s}^{-1}$ (ambos se denominan Sistema Morelos) y Maneadero de $0.20 \text{ m}^3\text{s}^{-1}$. Estos acueductos en conjunción con la presa El Carrizo son obras civiles para el abastecimiento de agua. Sin embargo la

infraestructura hidráulica para el almacenamiento de los recursos hídricos es escasa (IMIP, 2008), la última fue construida en 1978 hace más de 30 años para control de avenidas, por lo anterior se puede afirmar que las obras existentes son mínimas, inexistentes y obsoletas.

Es importante mencionar que la presas superficiales para aprovechamiento en la región a lo largo de su vida útil han permanecido prácticamente vacías o sea, dependen de la disponibilidad del recurso (CONAGUA, 2003), la presa Ing. Emilio López Zamora tiene una capacidad máxima de 6.86 hm^3 y su promedio de almacenamiento es de 2.54 hm^3 en el periodo de 1978 a 1998 de acuerdo al (IMIP, 2010) o sea, ha trabajado al 37% de su capacidad máxima. La presa más importante Abelardo L. Rodríguez tiene una capacidad máxima de 138.00 hm^3 , en el periodo 1948 a 1959 su promedio anual fue muy inferior a su capacidad (menor del 50%), en el periodo de 1960 a 1974 prácticamente cero (menos del 4%), el otro periodo seco fue de 1984 a 1992, aunque ha tenido periodos de auge como en los años 1978, 1979 y 1983 (CESPT, 2006; IMIP, 2008). En la RH01 se han realizado estudios para construcción de presas en diferentes zonas de la región, aunque los estudios geotécnicos han sido favorables, los estudios de viabilidad económica no lo han sido, principalmente por las condiciones climáticas regionales (IMIP, 2010). Es necesario cambiar la concepción de este tipo de obras civiles para que garanticen su funcionalidad hidráulica para ello se requiere modificar la normatividad nacional que dista mucho de las condiciones climáticas locales, o sea se requiere modificar la escasez institucional. Por lo anterior es vital para la RH01 el diseño de obras hidráulicas acordes a la región que capten los escurrimientos de las cuencas asegurando el suministro de agua y evitando riesgos a la población debido a las inundaciones.

1.3. Hidroeconomía

En esta región de acuerdo a las estimaciones del CONEPO en 2007 (CEA, 2008) la tasa de crecimiento de la población es de 3.0% derivado de la migración, de altas tasas de nacimiento y de declinación de los índices de

mortalidad (ver Figura 1.1). En el año 2010 eran 2'218,244 habitantes y se proyectan 4'146,418 para el 2030 estos datos implican un déficit de agua para el abastecimiento de agua a la población para esos años respectivamente de 38'915,424 y 165'973,968 m³/anuales (IMIP, 2010).

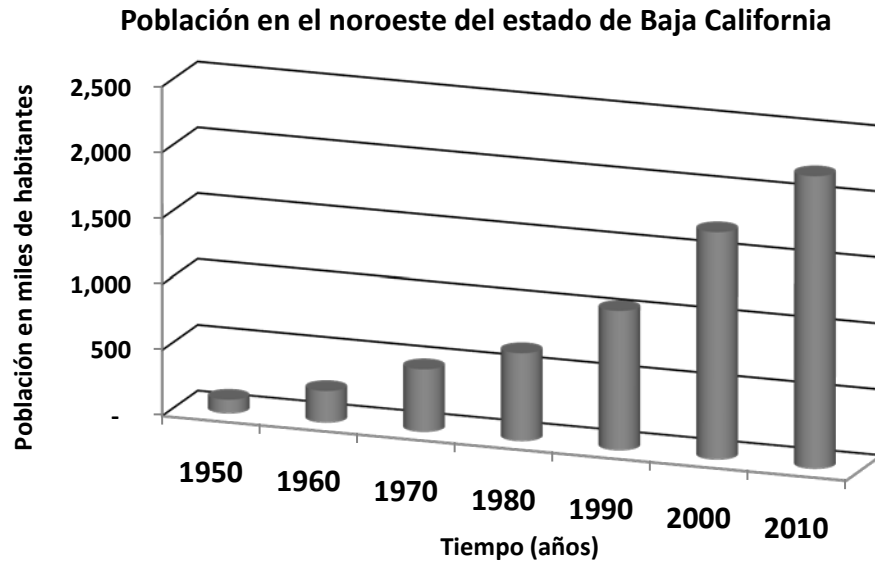


Figura 1.1 Crecimiento de la población en el noroeste del estado de Baja California, (elaboración propia, en relación a la base de datos por entidad federativa del INEGI, consultada en 2011).

1.3.1. Contradicciones

De acuerdo con Martínez (2000) las tres contradicciones del ciclo del hidrológico natural y artificial son: primera, se expresa como un problema cuantitativo de la relación a largo plazo entre volúmenes de agua que demandan los consumidores y usuarios, contra los que existen realmente como reserva aprovechable. Es decir, los consumidores y los usuarios crecen de manera inagotable y el recurso hídrico permanece prácticamente constante, en nuestra región hidrológica, la precipitación media permanecerá constante, lo que se encuentra en crecimiento es la población; segunda, se refiere al aspecto cualitativo del mismo problema, o sea, en la actualidad la demanda y reserva tanto en cantidad como en calidad geográficamente se encuentran en lugares distintos, en nuestro caso la fuente de agua relativamente perenne es el Río Colorado y se trasvasa a nuestra región hidrológica; tercera, tiene que ver con las dos anteriores y del grado de desarrollo social de las regiones, o sea, los

recursos técnicos y materiales que cuenta la sociedad para solucionarlos, en relación a sus carestías para lograr su progreso, en la región la infraestructura hidráulica para el aprovechamiento del recurso hídrico es prácticamente nula y data desde la construcción de la presa Ing. Emilio López Zamora. Estas tres contradicciones se cumplen cabalmente en la RH01.

1.4. Información Hidroclimatológica

Un factor que dificulta la toma de decisiones en la administración de los recursos hídricos en definitiva es la aleatoriedad de algunas variables como la precipitación pluvial. La carencia, ausencia o limitación de la información hidroclimatológica de calidad imposibilita un mejor conocimiento de la realidad y la construcción de proyecciones confiables de su evolución futura. Existen numerosos estudios hidrológicos basados únicamente en los registros de lluvias diarias, justificándose en la carencia de datos más precisos, en los últimos años (Campos, 2005 y 2008; Gutiérrez y Ramírez, 2005; Méndez, et al., 2006; González, et al. 2008 y Cisneros y Pelczer 2007), quienes mencionan la necesidad de contar con información suficiente en cantidad y calidad para aplicarla a modelos hidrológicos. Esta escasez de información para formular estudios hidrológicos invita a explorar nuevas metodologías de pronóstico para apoyar la gestión integrada de los recursos hídricos.

En la RH01 la información hidroclimatológica es proveniente de los registros valiosamente administrados por la Comisión Nacional del Agua (CONAGUA). Las estaciones climatológicas registran la información diariamente, se puede considerar que existe el registro de 40 estaciones de las cuales se encuentran en funcionamiento 16 que cuentan con más de 50 años de información, y recientemente se instalaron seis estaciones automáticas. De estos dos tipos de estaciones la mayoría se ubica a lo largo de las carreteras federales, en algunos casos estas estaciones son espaciadas por cientos de kilómetros. Además se cuenta con la información esporádica de seis estaciones hidrométricas.

Recientemente en el año 2002 la Secretaria de Fomento Agropecuario (SEFOA) ha instalado 17 estaciones automáticas en Baja California de las cuales 12

corresponden a la RH01 y debido a su función se encuentran ubicadas en los principales valles agrícolas. Dada la proximidad con los Estados Unidos, los datos registrados en el sur del Estado de California permite hacer uso de esta información. Por ejemplo, la red climatológica que presenta el *National Weather Service (NWS)*, presenta registros de precipitaciones pluviales desde 1850 algunas con intensidades de una hora e inclusive cada cinco minutos. También una alternativa viable y económica para solucionar el problema de la variabilidad espacial y temporal de los datos de precipitación, es utilizar la red de 155 radares meteorológicos de última generación modelo WSR-88D que tiene el *NWS* (ver Apéndice A), de los cuales 12 se encuentran en el Estado de California, EUA y el más cercano a la RH01 está ubicado en el condado de San Diego y se puede acceder a la información de la base de reflectividad del *Ratio Detection And Ranging (RADAR)*, en el Apéndice A se presenta mayor información en relación a este tema.

El objetivo para los ingenieros e investigadores en el campo de la hidrología es estimar como fluye y se distribuye el vital líquido después de precipitarse para que sea aprovechado por el ambiente, la actividad económica y la vida misma. Sin embargo, la simulación de este proceso es complejo, debido a que la precipitación es una variable distribuida, por esta razón un problema silencioso que acecha nuestro país y particularmente nuestra región es la escasez de este vital líquido y de la información hidroclimatológica. Los registros muestran que los eventos de precipitación en la RH01 tienen un comportamiento aleatorio produciendo fenómenos extremos como las inundaciones y sequías. De tal manera, que inferir su comportamiento se ha vuelto trascendental desde el punto de vista de la administración del recurso, por lo que mejorar la exactitud de los modelos utilizados para estimar un pronóstico es importante para el manejo integrado de los recursos hídricos. Esta investigación se realiza con el propósito de hacer más preciso el pronóstico de la ocurrencia de los eventos de precipitación para utilizarlos con diferentes fines como: la previsión de inundaciones, diseño de estructuras de protección, cuidado de los cultivos, entre otros. Y se emplean métodos de análisis de señales y de pronóstico que

aparecen en el estado actual del conocimiento como la Transformada Wavelet Discreta que es hábil para descomponer una señal en sus diferentes frecuencias y las Redes Neuronales Neurodifusas que es hábil para encontrar patrones de la serie de tiempo y predecirlos. De acuerdo a la literatura revisada estos métodos al emplearse de manera híbrida mejoran los indicadores de desempeño.

1.5. Objetivos

En esta investigación se utilizan la Transformada Wavelet en diferentes versiones la Transformada Wavelet Continua, el Análisis Wavelet Multiresolución, la Transformada Wavelet Discreta con dos técnicas: Mallat y Máxima Superposición (*MODWT*), además se emplean dos algoritmos de pronóstico en base a Redes Neuronales Artificiales el *Feed Forward Back Propagation (FFBP)* y el *Adaptive-Network-based Fuzzy Interface System (ANFIS)*. Estos métodos se conjugan y se obtienen novedosos métodos híbridos denominados Wavelet-Neuronales que recientemente se emplean en la literatura para el pronóstico de series climáticas y se discute la influencia del efecto de borde producto del filtrado en la predicción. Asimismo se utilizan indicadores de la teoría del caos para identificar el grado de aleatoriedad de las series. Los métodos utilizan los registros de precipitación mensual para buscar estructuras coherentes y realizar un pronóstico con fines de administración del recurso hídrico en la RH01.

1.5.1. Objetivo General

Generar un modelo para pronosticar los registros de precipitación pluvial en una estación climatológica en el noroeste del Estado de Baja California utilizando Transformada Wavelet, Redes Neuronales Artificiales y Neurodifusas.

1.5.2. Objetivos Específicos

1. Utilizar la metodología de análisis Transformada Wavelet (*WT*) con el propósito de descomponer las series de tiempo y buscar periodicidades.

2. Utilizar metodologías de pronóstico y reconocimiento de patrones Redes Neuronales Artificiales (*ANN*) y las redes neurodifusas (*ANFIS*).
3. Utilizar indicadores de la teoría del caos para analizar las series de tiempo.

1.6. Justificación

El desarrollo económico, social y ambiental del estado de Baja California depende de sus recursos, principalmente el recurso agua. La carencia, ausencia o limitación de la información hidroclimatológica de calidad imposibilita el conocimiento de la realidad y construcción de proyecciones confiables de su evolución futura. La necesidad de aprovechar al máximo la información climatológica costosa pero valiosa para países, en desarrollo como México, requiere de desarrollo metodologías de análisis y pronóstico como las que se proponen en esta investigación.

1.6.1. Justificación Técnica

Un pronóstico acertado permite una planeación adecuada. Este resultado es una proyección matemática de las técnicas de: Regresión Lineal y Auto Regresivos Integrados de Media Móvil. Asimismo en los últimos años han tenido auge técnicas como las redes neuronales artificiales y neurodifusas, y recientemente metodologías híbridas como las wavelet-neuronales que se han utilizado mediante la aplicación específica de la Transformada Wavelet Discreta en conjunción con las Redes Neuronales Artificiales o Neurodifusas aplicadas a series de tiempo climáticas lo cual es un campo poco utilizado. En la literatura científica revisada más especializada en hidrología específicamente en el campo del pronóstico de precipitación pluvial en los últimos 10 años apenas aparecen seis artículos que se aproximan al tema pero en otras latitudes.

1.6.2. Justificación Económica

Los estudios realizados facilitarán a las autoridades la toma de decisiones en relación a la administración de los recursos hídricos en la región, principalmente

en eventos extremos como sequías e inundaciones. Las primeras ocasionan daños severos que aunque sus pérdidas son difíciles de cuantificar el INEGI (2012) estima que alrededor de 48 millones de mexicanos padecen las consecuencias de la sequía en zonas áridas, semiáridas y subhúmedas secas. En relación a la segunda las pérdidas económicas producidas por el agua y sedimentos, en las regiones como Tijuana, Ensenada y San Quintín, han ocasionado la caída de puentes, falla en los taludes y estructuras de pavimento, debilitando el sistema de transporte y de energía eléctrica federal, estatal y municipal. Por ejemplo, las lluvias que azotaron al municipio de Ensenada del 21 al 23 de enero del 2010 provocaron daños por mil millones de pesos que fueron resueltos con recursos del Fondo Nacional de Desastres Naturales solamente en infraestructura (Vargas, 2010).

En la RH01 el anegamiento de los cultivos en las regiones eminentemente agrícolas provoca impactos negativos a sus economías. Además existen zonas donde hay un número importante de poblaciones pequeñas que quedan con problemas de acceso terrestre, con falta de insumos básicos a la población, afectando directamente la vida de las familias tiempo después de ocurridos los eventos climáticos.

En este tipo de eventos los gobiernos invierten recursos económicos extraordinarios debido a la falta de planeación hidráulica y de infraestructura adecuada para esta región climática. Inclusive se llega a formar un sistema administrativo burocrático que se justifica en la solución posterior de estos eventos.

Esta RH01 exige obras hidráulicas acordes con condiciones climáticas de la región que sean seguras, eficientes y de calidad. Es relevante generar y analizar alternativas para administrar y suministrar el vital líquido de manera eficiente y sustentable, así como para determinar la cantidad de obras necesarias para recarga, reúso, desalinización, etc., planeadas para largo plazo con métodos y técnicas aplicables a la zona que tiene un clima diferente a otras zonas del país pero con la misma normatividad.

1.6.3. Justificación Social

Asumiendo nuestra responsabilidad del manejo sustentable del recurso hídrico debemos asegurar el abastecimiento de agua para las generaciones futuras y sin descuidar su seguridad. Si así lo hacemos, mejoraremos la calidad de vida de los habitantes que se benefician de ella, la imagen urbana de las comunidades al generar espacios de esparcimiento, el microclima, la cultura por el uso racional del recurso, la salud pública y la producción de alimentos, asimismo se mitigarían conflictos ejidales, regionales e internacionales.

Las pérdidas de vidas humanas provocadas por las lluvias torrenciales de la zona, la movilización a albergues de familias completas y las consecuencias que generan, además de recursos humanos que trabajan sin planeación para dar soluciones puntuales a cada problema en específico, son algunas de las consecuencias de la falta de información fehaciente para lograr la óptima planeación del recurso agua realizándola organizadamente como un sistema.

1.6.4. Justificación Ambiental

Se ha hablado de la reutilización del agua tratada y la desalinización del agua de mar como la solución del problema del abastecimiento del agua a la RH01, metodologías que utilizan energías no renovables y por tanto muy costosas por la inversión inicial e insumos permanentes que requieren, sin embargo de acuerdo a (CONAGUA, 2003) casi 504'000,000 de metros cúbicos de agua sin uso aparente escurren al mar, estos aprovechan la energía sustentable suministrada al ciclo hidrológico a través del sol, la gravedad y la térmica del interior de la tierra, agua que se podría utilizar para la recarga de los acuíferos principal o única fuente de abastecimiento de agua para algunos usuarios de la zona.

Por lo anteriormente expuesto es importante desarrollar un programa a largo plazo con tecnologías recién desarrolladas alimentadas con datos fidedignos, tomando en cuenta las contradicciones del recurso agua, al ser humano y su entorno.

Capítulo II Estado Actual del Conocimiento

2.1. Introducción

Una gota de agua que cae de las nubes genera vida, trae energía y bienestar y en ocasiones destrucción, además un gran número de ellas al precipitarse sobre la corteza terrestre produce escurrimientos, infiltración y evaporación, procesos importantes para el equilibrio del planeta Tierra. Sin duda el primer paso para una gestión de los recursos hídricos es el modelado de la precipitación sobre las cuencas hidrográficas, esta variable es un fenómeno caótico que fluctúa en el tiempo y espacio. El conocimiento de los patrones de su comportamiento es una tarea sumamente complicada pero necesaria para los administradores de los recursos hídricos, debido a que existe la necesidad de prevenir o planificar eventos normales o extremos como sequías o inundaciones. Las series de tiempo de registros hidroclimatológicos tienen la característica esencial de ser no estacionarias y oscilatorias o no lineales. Sin embargo algunas veces por necesidad de dar solución a un problema específico, se tratan como estacionarios y con tendencias lineales. Los modelos usados tradicionalmente han sido ampliamente descritos en la literatura, tales como Regresión Lineal Múltiple (RLM) y Autorregresivos Integrados de Media Móvil (ARIMA) (Adamowski; 2008; Nourani et al., 2009; Dastorani et al., 2010; Remesan et al., 2009).

El concepto del Manejo Integrado de los Recursos Hídricos nos lleva de la mano para pensar en utilizar los datos hidroclimatológicos disponibles y aplicar nuevas técnicas como el análisis de señales y el pronóstico. En las últimas décadas se han importado de otras especialidades nuevas tecnologías de análisis de señales y pronóstico como las *Artificial Neural Networks (ANN)* y sus variantes. En estas redes no se involucran las variables físicas que están implicadas en los fenómenos, pero se pueden representar la no linealidad y la no estacionalidad de los datos meteorológicos que desempeñan un papel significativo en el pronóstico (Adamowski, 2008). Las *ANN* matemáticamente son a menudo vistas como aproximadores universales (ASCE, 2000a,b) y son caracterizadas por su

arquitectura (que representa el patrón de conexión entre los nodos), por su método para determinar el enlace entre los pesos, y la función de activación (ASCE, 2000a). Las ANN son muy hábiles para encontrar un patrón y predecirlo, además han sido extensamente utilizadas para la predicción de diversas variables hidrológicas: caudales, precipitación, sedimentos suspendidos, modelos lluvia-escorrentamiento, etc. (Partal, 2009; Kişi, 2009; Dastorani et al., 2010; Besaw et al., 2010).

Jang, (1993) introduce un método que denomina *Adaptive-Network-based Fuzzy Interface System (ANFIS)*. Este método es una adaptación de ANN con *Fuzzy Interface System (FIS)* para el modelado de los aspectos del conocimiento humano y procesos de razonamiento sin utilizar el análisis cualitativo preciso, con el propósito que se puedan interpretar de manera sencilla, con reglas difusas del tipo *if-then*. Un FIS emplea Funciones de Membresía MF, por ejemplo $\mu_A(x)$ que corresponde al grado en el cual el valor de x tiene el atributo A (pequeño, largo, etc.). Los parámetros del FIS están determinados por los algoritmos de aprendizaje de la ANN. La parte premisa es la entrada del modelo y la consecuente es la salida del modelo. Existen tres tipos de ANFIS; en el tipo I, la salida global es el promedio ponderado de las salidas de cada regla inducida por la fuerza de disparo de la regla y la salida de la MF. En el tipo II, la salida difusa global se deriva por la aplicación de una operación "max" a la salida difusa calificada. Y en el tipo III, se usan reglas difusas *if-then* también conocidas como Takagui y Sugeno, la salida de cada regla es una combinación lineal de las variables de entrada más una constante, y la salida final es el promedio ponderado de la salida de cada regla.

2.1.1. Estudios previos

2.1.1.1. Estudios previos ANN

Partal, (2009); Kişi, (2009); Dastorani et al., (2010) y Besaw el al., (2010), mencionan a varios autores que anteriormente han desarrollado investigaciones con ANN. Dastorani et al. (2010) aplicaron varias técnicas de ANN como *Time Lagged Recurrent Network (TLRN)* y ANFIS tipo III para la predicción de la

precipitación registrada por una estación en el centro de Irán con clima hiperárido empleando diversas variables climáticas como datos de entrada al modelo. Encuentran que *ANFIS* y *TLRN* son modelos eficientes para predecir las cantidades de precipitación 12 meses adelante. Besaw et al. (2010) predijeron el caudal de una cuenca no aforada utilizando el modelo *Generalized Regression Neural Network (GRNN)* y *Counterpropagation Network (CPN)* a estos les añadieron ciclos de retroalimentación recurrente. De acuerdo a este documento los autores entrenaron los datos flujo-clima de una cuenca y los utilizaron para predecir el caudal de una cuenca cercana, encontrando que las cuencas tienen el mismo patrón y que su método se puede generalizar para climas húmedos. Wu et al. (2010) usaron *ANN* modulares y técnicas de preprocesamiento como media móvil, análisis de los componentes principales y análisis de espectro singular, para predecir series de tiempo de lluvia con datos mensuales y diarios. Además de los mencionados por los autores anteriores por su particular interés debido a la ubicación geográfica del estudio, Silverman y Dracup, (2000) predijeron los patrones de lluvia en California, EUA, usando *ANN*. Particularmente en México se han utilizado las *ANN* en problemas hidrológicos; Molina y Aparicio (2006) utilizaron las *FFBP* para simular el tránsito de avenidas en cuatro casos, el primero se realizó con un experimento numérico, el segundo con datos históricos de la parte baja del río Usumacinta, el tercero con trenes de avenidas y el cuarto para el análisis de gastos históricos con influencias laterales, en otra cuenca. Por su parte, Cisneros y Pelczer, (2007) utilizaron las *ANN* para pronosticar alturas de precipitación con intervalos sucesivos de 15 minutos de tormentas con duración mínima de 1 hora 45 minutos, con la utilización de datos de lluvia de cuatro estaciones cercanas y la propia estación para encontrar el pronóstico. Con tal finalidad, usaron criterios estadísticos para suavizar los eventos máximos de las series de precipitación registradas, emplearon una variable sintética llamada tendencia esperada, los registros fueron tomados del Sistema de Aguas de la Ciudad de México. González et al. (2008) predijeron la evapotranspiración de referencia de los registros históricos de cinco años en “Valle del Fuerte” en el estado de Sinaloa, utilizando análisis

de los componentes principales para evaluar el grado de dependencia y su efecto en la red.

2.1.1.2. Estudios previos *DWT*

La Transformada Wavelet (*WT*) es una poderosa herramienta de análisis de señales, además muy útil para simular procesos no estacionarios como los son los eventos de precipitación y sobre todo aplicando al máximo herramientas computacionales (Torres e Infante, 2001). Estos métodos alimentados con datos hidroclimatológicos son cada vez más populares en aplicaciones de la gestión de recursos hídricos debido a su rápido desarrollo, requisitos mínimos de información, y la facilidad de utilización en tiempo real (Addison, 2002). Si bien pueden carecer de la capacidad de proporcionar material de interpretación y comprensión de los procesos de captación, son capaces de apegarse a la realidad de manera relativamente precisa (Adamowski, 2008).

Sin embargo es importante tener en cuenta lo mencionado en ASCE (2000b): la precipitación sirve como motor para la mayoría de los procesos hidrológicos, además predecirla es una tarea complicada porque presenta un grado amplio de variabilidad espacial y temporal. Partal y Kişi (2007) y Cisneros y Pelczer, (2007) mencionan que la predicción exacta de la precipitación es muy difícil debido a la complejidad de los procesos físicos involucrados. Por un lado, Partal y Kişi (2007) dicen que lo anterior ocurre especialmente en comparación con los datos de escorrentía y por su parte, Cisneros y Pelczer (2007) refieren que la correlación entre los valores de precipitación sucesivas puede ser menor en comparación con el mismo análisis de los valores de escorrentía, por ello el número de publicaciones para el pronóstico de precipitaciones es escaso.

En los últimos años ha emergido una poderosa, mejor y nueva herramienta de descomposición tiempo-frecuencia, ha sido encontrada particularmente útil para análisis de señales descritas como “sin periodo”. Tienen la habilidad de examinar la señal simultáneamente en el tiempo y la frecuencia. Además su propiedad multiescala la hace surgir como una herramienta poderosa, considerando un camino diferente a la tradicional transformada de Fourier por lo

que presenta ventajas claras frente a esta última metodología (Daubechies, 1988; Addison, 2002; Labat et al., 2005; Lobota et al., 2006; Becker et al., 2007; Partal y Kükük, 2006; Partal y Kişi, 2007, Adamoski, 2008, Nourani et al., 2009; por mencionar algunos).

Trabajar en el campo de las frecuencias es significativo debido a que se pueden ver características de la señal que pueden pasar desapercibidas cuando se analizan en la dimensión del espacio-tiempo. La *WT* fue introducida por Morlet y Grossman (1984) como una herramienta de análisis tiempo-escala para señales no estacionarias, además para estudiar las no linealidades y discontinuidades de datos irregulares. Asimismo, puede usarse para analizar series de tiempo que contienen no estacionalidades en muchas diferentes frecuencias (Daubechies, 1990). La *WT* consiste en descomponer una serie de tiempo en el espacio tiempo-frecuencia y determinar sus modos dominantes de variabilidad y cómo éstos se modifican en el tiempo (Torrence y Compo, 1998). En este proceso de transformación se mantiene la ubicación de la señal en el tiempo y es posible reconstruirla (Graps, 1995; Percival y Walden, 2000). La *WT* compara una señal con versiones dilatadas y trasladadas de ciertas funciones *wavelet* llamadas Wavelet Base o Madre (Graps, 2005; Remesan et al., 2009) que deben satisfacer ciertos requisitos matemáticos (Graps, 2005). Existen una variedad de estas funciones, entre ellas; Haar, Morlet, Daubechies, Symlets, Meyer y Coiflets. Su elección en una aplicación específica es muy importante y depende de una diversidad de factores, tales como la velocidad de cómputo, las características de la señal, la resolución de frecuencia, y el análisis estadístico a realizar (Addison et al., 2001). Numerosos autores coinciden en que el análisis de wavelet, es una herramienta más poderosa que la transformada de Fourier porque trabaja en el dominio de la frecuencia y tiene la ventaja de no perder la ubicación en el tiempo (Graps, 2005; Addison et al., 2001; Remesan et al., 2009), es decir, entrega información tiempo-frecuencia de manera aproximadamente simultánea eliminando casi por completo la barrera del tiempo (Becker et al., 2008; Casty et al., 2007; Coulibaly y Burn, 2005; Hartmann et al., 2008), o sea, permite el uso de largos intervalos de tiempo para obtener

información de baja frecuencia y viceversa.

Mediante este tipo de transformaciones la señal se examina a diferentes frecuencias con diferentes resoluciones lo que se llama concepto multiresolución o también análisis wavelet multiresolución (*WMA*) desarrollado por Mallat y Meyer (Daubechies, 1990 y 1992) y documentado en Mallat (1989).

Es importante comentar que es común que la *WT* se utilice en conjunto con las *ANN* y en la frontera del conocimiento se encuentra el uso de la *WT* con métodos Neuro-Difusos (Partal y Kişi, 2007).

Como se mencionó anteriormente se han generado un número importante de sofisticados métodos wavelet base para la manipulación y cuestionamientos para la señal. El análisis wavelet se ha investigado en una serie de disciplinas fuera de la ingeniería de los recursos hídricos y la hidrología, y ha resultado ser muy eficaz con los datos no estacionarios (Partal y Kükük, 2006).

La *WT* ofrece un marco de las series de tiempo descompuestas en nuevas series, cada una de ellas con una disminución del grado de resolución lo que permite separar la información de detalle espacial de la serie, entre dos grados de resolución sucesivos. El análisis multiresolución, basado en teoría wavelet, permite la descomposición de datos en diferentes componentes de frecuencia, así como el estudio de cada componente con una resolución correspondiente a su tamaño. En una diferente resolución, los detalles de una serie, por ejemplo componentes de alta frecuencia, determina los diferentes atributos de las características físicas de la serie (Mallat, 1989). En una baja resolución, estos datos corresponden a las estructuras más grandes, mientras que en un análisis más detallado de resolución, esta información corresponde a las estructuras de menor tamaño (Graps, 1995).

La teoría wavelet se divide en dos tipos de transformaciones, *WT* Continua (*CWT*) y *WT* Discreta (*DWT*) (Daubechies, 1992; Katul y Parlange, 1995; Addison et al. 2001), ambas utilizan las funciones wavelet base o madre mencionadas arriba. La *CWT* es esencialmente una herramienta de análisis exploratorio de datos que puede ayudar al ojo humano a distinguir características de su interés (Percival y Walden, 2000). Existe suficiente

evidencia en la literatura de la utilización del *WMA* con *CWT*, aunque en ocasiones se adapta a la *DWT*, pero el concepto es prácticamente el mismo.

En el campo de la climatología, Morata et al. (2006), analizan las variaciones intraestacionales de la precipitación diaria en Tailandia y el acompañamiento de la variación de la circulación de la tropósfera, durante el año de 1998. Casty et al. (2007), estudiaron los patrones de climatología europeos para una presión atmosférica constante sobre la evolución temporal y espacial de la temperatura y la precipitación encontrando que no hay tendencia clara de la precipitación, no obstante, observan una importante significancia del efecto de borde. Por su parte, Minobe et al. (2002), analizan los cambios en estructuras temporales de oscilación bidecenal del clima sobre el hemisferio norte en el período de 1899 al 2000.

En el campo de la hidrometeorología, Brunsell y Gillies (2002), a partir de información de sensores remotos en el aire y satelitales, analizan el balance de datos de flujo de energía turbulento en la interacción tierra atmósfera debido a la variabilidad de la vegetación. Coulibaly y Burn (2005), analizan la variabilidad espacial y temporal de los caudales de los ríos en las estaciones anuales y la variabilidad climática del hemisferio norte utilizando el *MWA* y correlación cruzada. MacDonald y Tingstad (2007) analizaron la relación de las sequías con los regímenes recientes de precipitación en las montañas de Utah, EUA, a partir de la comparación de los registros de precipitación reconstruidos con anillos de árboles durante 600 años. Mwale y Gan (2005) aplicaron *WMA* y análisis wavelet de los componentes principales para identificar zonas homogéneas de variabilidad y predictividad de lluvia, de Septiembre a Noviembre en el Este de África. Esta predicción la realizaron con una *ANN* calibrada con un algoritmo genético. Mwale et al. (2007) mediante análisis wavelet basado en funciones empíricas ortogonales estudiaron los regímenes no estacionarios temporales y frecuenciales de la variabilidad regional de las lluvias de verano (Octubre-Marzo) en el sur de África. Nolin y Hall-McKim (2006) utilizaron registros de precipitación diaria para realizar análisis de la variabilidad interanual y intraestacional del monzón de América del norte, en Arizona y Nuevo México EUA. Xue et al.

(2005) estudiaron la variabilidad de los escurrimientos de ríos y su relación interanual, bienal y a largo plazo utilizando la precipitación y la temperatura de la superficie del mar en China. Yokoi y Satomura (2005) analizan variaciones intraestacionales de la precipitación diaria y el acompañamiento de la circulación troposférica. Yokoi et al. (2007) estudiaron las características climatológicas de tres variaciones intraestacionales de precipitación sobre la península de Indochina.

En Hidrología, Golitsyn et al. (2002) realizan un *WMA* de las componentes del balance hídrico de los lagos Ladoga y Onega, incluyendo características especiales de las variaciones a largo plazo de los niveles de agua. Hartmann et al. (2008) realizan un análisis espectral de autocorrelación y *WMA* para demostrar la cuasi-periodicidad de las series de tiempo de precipitación en China. Partal y Kükük (2006), realizan un análisis de tendencia a largo plazo de mediciones de precipitación anual en Turquía. Adamowski (2008), predice las inundaciones del un río Rideau producto del deshielo de primavera para 1, 2 y 6 días, utilizando la transformada inversa de Fourier para reconstrucción. Kirkup et al. (2001) evalúan la variabilidad de las descargas y la precipitación en cuencas costeras en Australia.

Existen dos estudios en la literatura reciente que presentan el estado del arte en su momento, que considero importante mencionar, ellos son Labat (2005) y Adamowski (2008), ya que ambos trabajos elaboran un ejemplo con todas las técnicas encontradas y las comparan inclusive con técnicas estadísticas de antemano sobre entendidas. Después en esta sección se presentan las investigaciones más importantes y recientes en relación a la utilización de la *DWT* en el campo de la ingeniería de los recursos hídricos.

Labat (2005), elabora una revisión de las más recientes aplicaciones wavelet en el campo de las ciencias de la tierra y se dedica a la introducción e ilustración de estos nuevos métodos de análisis wavelet en el campo de la hidrología. El análisis wavelet sigue siendo desconocida en el ámbito de la hidrología a pesar de que claramente supera los límites bien conocidos de los clásicos análisis de Fourier. Nuevos instrumentos basados en wavelets se proponen a los

hidrólogos, a fin de hacer más atractivo el análisis wavelet. En primer lugar, un método de análisis wavelet continuo multiresolución muestra mejorar significativamente la determinación de la escala temporal de una determinada estructura de la señal. En segundo lugar, la entropía en los marcos de la *CWT* que desaparece al introducir el concepto multiresolución de manera que permitió una estimación de la evolución temporal de una determinada señal hidrológica o climatológica compleja. Nuevas perspectivas de la relación escala-dependencia están expuestas mediante la introducción de correlación cruzada y coherencia wavelet. Correlación cruzada wavelet continua proporciona un escenario de distribución de la similitud entre dos señales, mientras que la coherencia continua wavelet proporciona una estimación cualitativa de la evolución temporal del grado de linealidad de la relación entre dos señales en una escala dada. Estos métodos se aplican a los cuatro grandes escurrimientos del río y dos índices climáticos globales en su trabajo.

Según Adamowski (2008), hay una serie de ventajas en la utilización de análisis wavelet para el pronóstico de inundaciones en las áreas de la hidrología, que se ha explorado en detalle en la literatura y que desarrolla en su trabajo:

- 1.- El uso de análisis wavelet como técnica autónoma para el pronóstico de inundaciones producidas por ríos a corto plazo. La utilización de método pronóstico wavelet autónomo basado en modelos de predicción diaria permitiría a los usuarios aprovechar plenamente uno de los puntos fuertes del análisis wavelet, que es su capacidad para manejar datos no estacionarios día a día, porque el wavelet y wavelets transversales derivan valores diarios de amplitud, longitud de onda, fase y diferencia de fase que pueden utilizarse en los modelos de pronóstico.
- 2.- El uso de análisis de wavelet transversal en el desarrollo de corto plazo de los modelos de predicción de inundaciones fluviales. Ejemplifica esta característica utilizándola para determinar la diferencias de fase entre las señales de flujo y meteorológica.
- 3.- El uso de descomposición wavelet de datos meteorológicos en combinación con series de flujos para el desarrollo de modelos de pronóstico de inundaciones

del ríos a corto plazo. Utilizó la descomposición wavelet de datos meteorológicos para pronóstico de inundaciones y una constante de calibración que se desarrolló el autor para longitudes de onda específicas entre de flujo y los ciclos meteorológicos.

4.- El uso de la técnica desarrollada de corrección de efecto de borde para la *CWT* para dividir artificialmente los datos. Desarrolló una técnica para la corrección de efecto de borde considerando discontinuidades y saltos resultantes de datos artificiales por el efecto de borde.

5.- El uso de una versión modificada de la transformada de Fourier inversa con la constante de calibración y corrección de efecto de borde para pronóstico de inundaciones de río a corto plazo. Apunta que la transformada de Fourier inversa se puede utilizar para reconstruir las señales de descomposición wavelet. Sin embargo, el estudio aporta una reconstrucción más precisa, aplicando una corrección de efecto de borde y constante de calibración para señales meteorológicas.

Recientemente han surgido nuevas técnicas de preprocesamiento para ayudar en el pronóstico de algunos eventos climáticos como la precipitación y sus variables asociadas, atendiendo el conocimiento profundo de la no linealidad del sistema climático, por ejemplo (Wu et al., 2010; Besaw et al., 2010; Remesan et al., 2009). Esta nueva perspectiva se desarrolla principalmente con la *DWT* junto con una herramienta estadística, ambas son utilizadas como métodos de preprocesamiento de datos. Este preprocesado acoplado a algún algoritmo de pronóstico principalmente *ANN*, o cualquiera de sus variantes, han ganado terreno en el pronóstico de series climáticas sobre otros métodos (Kişi, 2009; Partal, 2009; Remesan et al., 2009; Shiri y Kişi, 2010; Adamowski y Sun, 2010). El acoplamiento de ambos procesos se conoce como modelo Wavelet-Neuronal (*WN*).

2.1.1.3. Estudios previos modelos híbridos

Existen tres enfoques de preprocesamiento reportados en la literatura. El primero se basa en descomponer la señal con *DWT* y utilizar las

descomposiciones como insumos a las *ANN* o alguna de sus variaciones (Nourani et al., 2009; Remesan et al., 2009; Kişi, 2009; Partal, 2009; Adamowsky y Sun, 2010; Adamowsky y Chan, 2011; Rajaei et al., 2011). El segundo enfoque consiste en suavizar la señal y una vez encontrada una nueva señal se predice su comportamiento. Ejemplos de este enfoque son mencionados por Partal y Kişi (2007); Shiri y Kisi (2010); Partal (2009); Wu et al. (2009); además Tiwari y Chatterjee (2010). Este enfoque tiene el problema de pérdida de información en el proceso del suavizado. Remesan et al. (2009) concluyen que es más conveniente trabajar con los datos crudos, debido a que se trabaja siempre con la señal original sin modificarla o suavizarla. El tercero es de Descomposición-Pronóstico-Reconstrucción, se descomponen las series en subseñales con la *DWT*, cada una de ellas se predice utilizando alguna herramienta para este fin y por último a partir de las subseries pronosticadas se reconstruye la serie original, utilizando la transformación inversa o *ANN*, esta última técnica la utiliza Kim y Valdés (2003). Los enfoques presentan el problema del fenómeno del efecto de borde producto de la transformada, el inconveniente es que precisamente estos datos del final de la serie son los que se utilizan para realizar el pronóstico. Pese a la importancia del fenómeno para la predicción no se menciona en la literatura con la temática del *DWT*, en el *WMA* se nombra para otros fines. Kim y Valdés (2003) utilizan un método de espejo para realizar el rellenado de la serie de tiempo en el proceso de filtrado, Adamowski (2008) aplica un método para el corte de datos y para los bordes, es decir, cada método implica un efecto de borde diferente. Para explicar este fenómeno debemos citar el método de la convolución, que es el procedimiento que utiliza la transformada para llevarse a cabo. En ella los coeficientes wavelet utilizados para el filtrado son deslizados a lo largo de la señal, al inicio se emplean los valores que se sitúan adelante de la serie o sea los futuros, al final de éste la señal se acaba pero el proceso aún no ha terminado. Para completar el proceso se requiere obtener una serie de valores, existen varios procedimientos para solucionar este problema. A continuación, se mencionan cuatro de ellos clásicos, el primero consiste en realizar un espejo de los últimos

valores, como lo utilizan Kim y Valdés (2003) y Adamowski (2008), que consiste en repetir después del último valor de la serie, el penúltimo, posteriormente el antepenúltimo y así sucesivamente hasta lograr el relleno; el segundo, se llama circular y se basa en repetir el inicio de la serie, o sea el primer valor, después el segundo, el tercero, etc. hasta lograr el objetivo; el tercero, asigna la media de la señal y ; en el cuarto se colocan ceros, en una determinada simulación el usuario puede asignar los valores que desee. Esto tiene una implicación en el pronóstico debido a que se convierte en una predicción implícita sobre la que se desea realizar, pero en el primer caso cuando se utiliza el método de relleno se colocan valores arbitrarios y en el segundo caso se emplea un método robusto de predicción. Existen diferentes algoritmos para realizar la *DWT* de los cuales se mencionan los tres más utilizados, estos posteriormente se explicarán con mayor detalle, en esta ocasión solo se comenta su relación con el efecto de borde: el '*à trous*' (con agujeros) es el que presenta mayor penetración en la señal y específicamente es el número de coeficientes del wavelet madre por dos menos dos por cada nivel. En el *MODWT* en cada nivel se introduce el número de coeficientes menos uno y en el de Mallat conforme se baja de nivel avanza el número de coeficientes de escalamiento menos dos, pero producto de las decimaciones la señal se va reduciendo en mitades cada vez. Este último algoritmo con el wavelet de Haar no presenta efecto de borde debido a que solamente tiene dos coeficientes de escalamiento y wavelet (Cornish et al., 2006).

La aplicación de estos tres enfoques se ha reportado en literatura para diversos tipos de datos, incluyendo los hidrológicos. Kim y Valdés, (2003) proponen un modelo conjunto *WN* basado en la *WT* diádica empleando el algoritmo '*à trous*' en conjunción con el clásico algoritmo de *FFBP* para pronosticar el índice regional de sequías en la cuenca del río Conchos en México, principal tributario de la parte baja del río Grande/Bravo. Ellos encuentran que el modelo híbrido *WN* mejora significativamente la habilidad de la *ANN* para pronosticar el índice regional de sequías, utilizan la *ANN* para reconstrucción de la serie en lugar de la transformación inversa. Por su parte, Partal (2009) utiliza un método *WN* para

estimar la evapotranspiración de referencia en el área de San Diego, California, EUA, utiliza el clásico algoritmo de Mallat acoplada a una *FFBP* con varias variables climáticas como datos de entrada al modelo. Los resultados demuestran que el método que propone puede ser también utilizado para estimar este parámetro. Kişi, (2009) presenta la aplicación de un método *WN* para el pronóstico de los niveles mensuales de dos lagos en Turquía, los resultados demuestran que el modelo *WN* mejora los obtenidos por la *ANN* con datos cuya antelación varia entres uno y seis meses. En el pronóstico de precipitaciones Partal y Kişi (2007) presentan un modelo de conjunción Wavelet Neuro-Difuso para el pronóstico de la precipitación diaria en Turquía. El modelo descompone las series de tiempo diarias de tres estaciones meteorológicas mediante la *WT* con el algoritmo de Mallat, la etapa de pronóstico la realizan mediante *ANFIS* Tipo III. Nourani et al. (2009) se basan en un modelo *WN* para el pronóstico de lluvias mensuales en una cuenca al noroeste de Irán. La serie de tiempo mensual se descompone en subseñales por medio de la *DWT*, utilizando una versión modificada o antecesora del algoritmo de Mallat al modificar el eje del tiempo por lo que la denominan base espaciada logarítmica. El método propuesto *WN* mejora el desempeño en la predicción.

En escorrentía, Remesan et al. (2009) utilizan un modelo para evaluar el modelado de escurrimiento de la lluvia mediante un modelo conjunto *WN* y la prueba Gama. Esta prueba se utiliza para identificar la estructura del modelo y la longitud requerida de los datos de entrada y presentan una discusión sobre este último parámetro. Shiri y Kişi (2010) desarrollan un modelo Wavelet Neuro-Difuso para modelar los caudales de series anuales, mensuales y diarias. Encuentran que el modelo Wavelet Neuro-Difuso mejora la exactitud del modelo en relación con el modelo Neuro-Difuso. Tiwari y Chatterjee (2010) desarrollaron un modelo Wavelet-BootStrap-*ANN* para pronosticar el flujo horario de un río en India utilizando los niveles del agua como datos de entrada. Adamowski (2008) presenta un método autónomo de pronóstico a corto plazo de las inundaciones debidas al deshielo de primavera producidas por el río Rideau, en Ontario, Canadá, se utilizó análisis wavelet y wavelet transversal para descomponer

series de tiempo de datos de flujo y meteorológicos, además, desarrollo componentes basadas en wavelet que luego utiliza para pronosticar las inundaciones con 1, 2, y 6 días de antelación. En esta investigación la propuesta del método de pronóstico de inundaciones del río basado en wavelets se puede utilizar con gran precisión como método autónomo de pronóstico de 1 y 2 días es el resultado más significativo. Wu et al. (2009) utilizaron métodos para mejorar el desempeño de *FFBP* con datos diarios de flujo, estos son: media móvil, análisis de espectro singular y *WMA*. Concluyen que el análisis del espectro singular mejora la medida de desempeño del modelo en comparación con *WMA*.

Adamowski y Chan (2011) pronosticaron niveles de agua subterránea utilizando modelos clásicos como *ARIMA* y proponen un modelo *WN*. Todos ellos concluyen que el modelo *WN* mejora el desempeño con respecto a la utilización del modelo de pronóstico autónomo.

En este trabajo se analizan los dos primeros enfoques de pronóstico, y se desarrolla con los algoritmos de la *MODWT* y de Mallat aplicando el *FFBP* y el *ANFIS* a datos de precipitación mensuales, con el propósito de realizar un pronóstico inmediato de la precipitación con un mes de anticipación en una región con clima seco templado del estado de Baja California, México. Se discute la influencia del efecto de borde en el pronóstico.

2.2. Marco teórico

2.2.1. Transformada Wavelet

La *WT* es una descomposición tiempo frecuencia, que usa funciones wavelet localizadas en tiempo y frecuencia (Daubechies, 1990). Es una radiografía de una señal, debido a que convierte la señal original en otra forma que hace más fácil su análisis ya que resalta ciertas características para su estudio (Addison, 2002). Una característica de la *WT* es que se utiliza pequeñas ondas diminutas llamadas wavelet madre (*WM*) o base $\psi(t)$. Se representan con funciones matemáticas (ecuación 2.1), que le dan una representación en la escala a y localización b , en las series de tiempo y sus relaciones con las escalas más

bajas para analizar el contenido de los datos no estacionarios.

$$\psi\left(\frac{t-b}{a}\right) \quad (2.1)$$

Las *WM* se manipulan a través de procesos de translación, movimiento a lo largo del eje del tiempo y es la ubicación que tendrá la función wavelet correspondiente a la información de tiempo. La dilatación con el propósito de expandirla o contraerla y así abarcar toda la señal. Esto le permite a la *WM* manejar la frecuencia y el tiempo (Mallat, 1989 y 1999; Nourani et al., 2008; Partal y Kükü, 2006; Partal y Kişi, 2007; por mencionar algunos). Por ejemplo, en series de tiempo de lluvia, se puede conocer el intervalo de tiempo en el que ocurren las precipitaciones pluviales a diferentes escalas o espaciamentos.

Estas wavelet madre $\psi(t)$ deben cumplir ciertos criterios matemáticos para ser llamadas como tal, deben ser una función cuya integral sea cero, quiere decir que oscilan sobre el eje x, asimismo deben tener soporte compacto, o sea sólo debe existir en un corto intervalo de tiempo (Mallat, 1989 y 1999; Daubechies 1988, Castleman, 1979, Graps, 1995, Addison, 2002, entre otros), es importante su elección y nivel de descomposición debido a que será utilizada como medida de semejanza y de ella depende la aproximación de la descomposición wavelet de la señal. (Daubechies, 1988 y Mallat 1989; por mencionar a los pioneros).

Cabe resaltar que en cada nivel de resolución la señal se va transformando en otra señal conociendo su tiempo y frecuencia. También permite el uso de intervalos de tiempo largo para la información de baja frecuencia e intervalos de información más cortos para la alta frecuencia y es capaz de revelar aspectos de los datos como las tendencias, puntos de ruptura, y discontinuidades que en otras técnicas de análisis de señales pueden perderse. Además, otra ventaja de la *WT* es la flexibilidad de la elección de la wavelet madre en función de las características de las series de tiempo que se están investigando (Addison, 2002).

Existe un extenso número de funciones que pueden ser consideradas como *WM* para el análisis de datos tales como: Haar, Daubechies, Morlet, Symlet. Para propósitos de una aplicación particular se aplica una *WM* dependiendo de dos

factores principales; la naturaleza de la señal y que queremos hacer en el análisis (Addison, 2002). En la figura 2.1 se presentan diferentes funciones que pueden ser consideradas como *WM*, por ejemplo la *WM* Sombrero Mexicano definido por la ecuación 2.2 y representada en la figura 2.1 b). Cabe aclarar que esta *WM* es muy buena para aplicaciones del caso continuo, matemáticamente es la segunda derivada de la distribución Gaussiana que tiene varianza uno y factor de normalización $1/\sqrt{2\pi}$. Se puede decir que todas las derivadas de la función Gaussiana pueden utilizarse como *WM*, el más apropiado depende de la aplicación (Addison, 2002).

$$\psi\left(\frac{t-b}{a}\right) = \left(1 - \left(\frac{t-b}{a}\right)^2\right) e^{-[1/2(t-b/a)]^2} \quad (2.2)$$

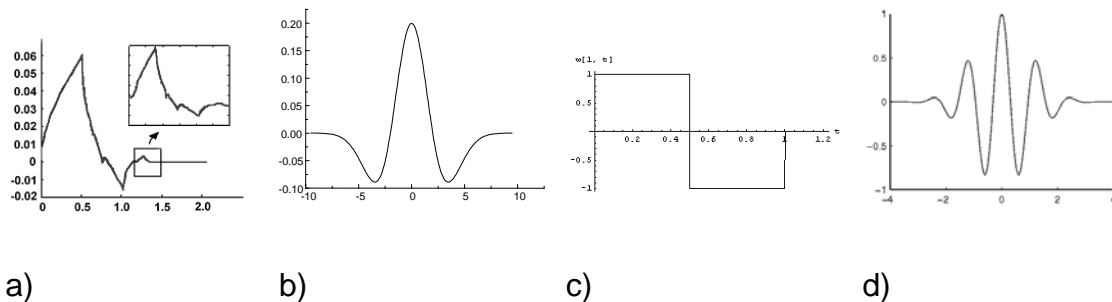


Figura 2.1. Funciones wavelet madre. a) Daubechies, b) Sombrero Mexicano, c) Haar y d) Morlet

En el caso de análisis de series de tiempo de datos climatológicos, que usualmente tienen la propiedad de ser no estacionarios, la función de Morlet ha probado ser una *WM* muy apropiada para análisis continuo debido a que es particularmente bueno para resaltar estructuras que contienen variaciones de energía bruscos (Mwale y Gan, 2005; Yokoi y Satomura, 2005; Becker et al, 2008; Torrence y Webster, 1999; por mencionar algunos), sin embargo para el caso discreto es imposible utilizarla porque esta función insatisface la condición del de soporte compacto, por esta razón se utilizan otras *WM* que cumplan cabalmente con las condiciones (Addison 2002).

2.2.1.1. Transformada Wavelet Continua

Después de elegir la WM , inicia el trabajo de la Transformada Wavelet Continua (CWT) que se expresa en la ecuación 2.3, esta genera una familia de funciones cuyos miembros son convolucionados con la señal $s(t)$ para así obtener su transformada, debido a que deben existir versiones del WM ubicadas de tal manera que cubran toda la señal (Torrence y Combo, 1998; Minobe et al., 2002; Tomas y Foken 2005; MacDonald y Tingstad, 2007; por mencionar algunos).

La CWT de una función $s(t)$ es definida por la ecuación 2.3.

$$T(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} s(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (2.3)$$

donde $\psi(t-b)/a$ es una función wavelet admisible y se utiliza para analizar la señal $s(t)$. Los coeficientes de transformación $T(a, b)$ son encontrados para una localización específica, $t = b$. y para un periodo específico wavelet que es función de a que es el parámetro de escala. El asterisco indica que es el complejo conjugado de la función (Addison, 2002; Partal y Kükü, 2006; Partal y Kişi, 2007; entre otros), para el caso de transformadas elaboradas con funciones complejas como el Morlet.

Para ser clasificado como wavelet, una función debe tener energía finita, y se debe cumplir la condición de admisibilidad siguiente, ecuación 2.4:

$$C_{\psi} = \int_{-\infty}^{\infty} \frac{|\hat{\psi}(\omega)|}{|\omega|} d\omega < \infty \quad (2.4)$$

donde C_{ψ} es conocida como constante de admisibilidad y $\hat{\psi}(\omega)$ = transformada de Fourier de $s(t)$.

La energía total en la señal puede ser encontrada por la ecuación 2.5:

$$E = \frac{1}{C_{\psi}} \int_{-\infty}^{\infty} \int_0^{\infty} \frac{1}{a^2} |T(a, b)|^2 da db \left[= \int_{-\infty}^{\infty} s(t)^2 dt \right] \quad (2.5)$$

La contribución de la energía total contenida en la señal en una escala específica a es dada por la ecuación 2.6:

$$E(a) \int_{-\infty}^{\infty} |T(a, b)|^2 db \quad (2.6)$$

Además, la contribución de la energía de la señal en una escala específica a y localización b es dada por la función de densidad de energía wavelet en dos dimensiones, que puede ser utilizada para caracterizar estructuras dominantes, ecuación 2.7.

$$E(a) = |T(a, b)|^2 \quad (2.7)$$

Como en la transformada de Fourier, la señal original puede ser reconstruida usando la WT inversa, ecuación 2.8.

$$s(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \int_0^{\infty} \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) T(a, b) \frac{da db}{a^2} \quad (2.8)$$

Para utilizar la CWT en un grupo de datos discretos se requiere una discretización de la ecuación, basados en una regla trapezoidal, ecuación 2.9.

$$T(a, b) = \frac{1}{2\sqrt{a}} \sum_{i=1}^{J-1} \left[\psi\left(\frac{t_i - b}{a}\right) s_i + \psi\left(\frac{t_{i+1} - b}{a}\right) s_i \right] \Delta t \quad (2.9)$$

donde s_i = vector de datos discretos que tiene una longitud de N muestras; t_i = tiempo discreto asociado con s_i ; y Δt = es el intervalo de muestreo. La transformada es calculada por un rango de N valores discretos de a y b . La ecuación 2.10 es la más simple discretización de la CWT y es llamada CWT discretizada ($DCWT$). Esta transformada produce N^2 coeficientes para un grupo de datos de longitud N ; por lo tanto, información adicional o redundante está guardada dentro de los coeficientes (Katul et al., 1998), que puede o no ser una característica deseada. Hay transformadas alternativas que usan funciones wavelet que pueden solamente ser descritas en una forma discreta usando una representación más tosca se conocen como wavelet discretas y su correspondiente DWT .

El diagrama $T(a, b)$ con sus respectivos parámetros a y b es conocido como escalograma, éste muestra los valores de similitud de la señal con el wavelet a determinada escala y con determinado desplazamiento (Graps, 1995; Percival y Walden, 2000, además Torrence y Compo, 1999). Así, en este tipo de diagrama se puede apreciar información de frecuencia (escala) y tiempo (desplazamiento), como se muestra en la figura 2.2.

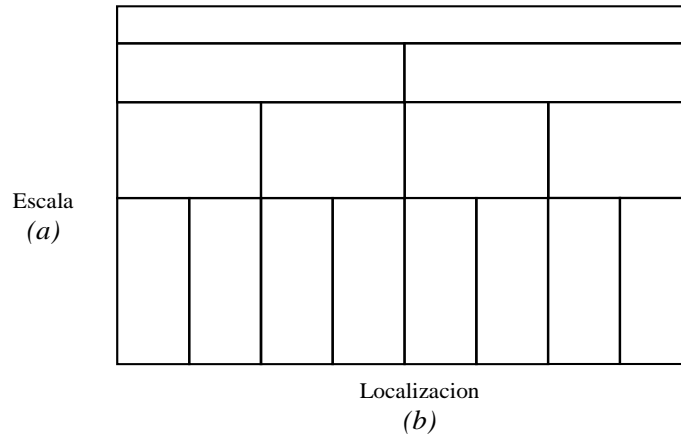


Figura 2.2. Esquema de un Escalograma, escala a y localización b .

El escalograma es una representación gráfica real donde las celdas se iluminan a diferentes intensidades, esto permite comparar la localización, escala-frecuencia e intensidad. Es decir, en un intervalo de tiempo determinado se puede ver la potencia de la señal a una escala determinada. La frecuencia que corresponde con la intensidad equivalente de cada celda. Los picos en $E(a)$ luces brillantes es la escala de energía dominante en la señal.

Aprovechando la propiedad multiescala de la WT y su representación gráfica se pueden comparar señales a diferentes resoluciones, por ejemplo: en series climatológicas se pueden comparar datos a diferentes intervalos de tiempo. Esto es útil cuando se presentan series con datos faltantes, pues se pueden comparar series con intervalos de registro diferente. Por ejemplo, se pueden comparar series con intervalos de registro de una hora, contra series con intervalos de registro de un día (Rousseau, et al., 2004). En la figura 2.3 se presenta un segmento del escalograma para la descomposición de la lluvia por la CWT para la ciudad de Ensenada.

2.2.1.2. Transformada Wavelet Discreta

Los parámetros de tiempo y escala de una CWT son ejemplificados de forma discreta mediante la construcción de los marcos wavelet. La familia de funciones wavelet que se construyen en un marco, es tal que la energía de los coeficientes resultantes es la misma, mientras está adentro de cierto rango limitado de

energía de la señal original, por ejemplo A y B , donde la señal $s(t)$ se define para tener energía finita.



Figura 2.3. Escalograma de una serie de tiempo de la estación Ensenada correspondiente a datos de lluvia.

Los valores límites A y B se asocian a unos parámetros, por ejemplo escala a_0 y translación b_0 escogidos para el análisis y la función wavelet utilizada (Daubechies, 1988). Si $A = B$ el marco es conocido como “Apretado”, cuando $A > 1$ y $B > 1$ es “redundante”, en el ejemplo A es una medida de la redundancia. Sin embargo, cuando $A = B = 1$ la familia wavelet definida por la forma del marco es una ortonormal básica (Addison, 2001).

La CWT y su discretización, son redundantes; esto es, la señal que para aplicaciones prácticas será un grupo de datos discretos, es sobremuestreada por los coeficientes de transformación. Esto hace que la realización del tiempo de cómputo sea costosa desde ese punto de vista.

Para construir una base wavelet ortonormal completa se utiliza una base espaciada logarítmica (Mallat, 1989 y 1999) para discretizar la escala a_0 con su correspondiente menor resolución de la localización b_0 . Esto permite describir completamente una señal de longitud N con cero redundancia para los N coeficientes de transformación. Esos wavelet discretos como el nombre lo indica no son ubicados continuamente, más bien tienen una localización discreta sobre el eje del tiempo. De igual forma el resultado de la DWT puede solamente ser trasladado y dilatado en saltos discretos. La DWT tiene la forma de la ecuación 2.10:

$$\psi_{j,n} \left(\frac{t-b}{a} \right) = \frac{1}{\sqrt{a_0^j}} \psi \left(\frac{t-nb_0a_0^j}{a_0^j} \right) \quad (2.10)$$

donde j y n son enteros para la dilatación y translación del wavelet, respectivamente; a_0 es el paso fijo de dilatación mayor a uno; y b_0 es el parámetro de localización mayor a cero. Para esta ecuación, se puede ver que el paso de translación de $nb_0a_0^j$ depende de la dilatación, a_0^j . Mallat (1999) propuso discretizar los valores de a_0 y b_0 , asignándole 2 y 1 respectivamente. Este escalamiento aritmético logarítmico potencia de dos de las translaciones y dilataciones es conocido como arreglo de malla diádica y es el caso más simple y eficiente para propósitos prácticos. La wavelet diádica puede ser escrita en notación compacta como, ecuación 2.11 (Addison, 2002; Partal y Kükü, 2006; Partal y Kişi, 2007; Nourani 2009):

$$\psi_{j,n}(t) = 2^{-j/2} \psi(2^{-j}t - n) \quad (2.11)$$

Comúnmente se prefiere escribir de esta forma el wavelet discreto diádico ortonormal y presenta la siguiente propiedad, ecuación 2.12:

$$\int_{-\infty}^{\infty} \psi_{j,n}(t) \psi_{j',n'}(t) dt = \delta_{j,j'} \delta_{n,n'} \quad (2.12)$$

donde $\delta_{i,j}$ es la función delta de Kronecker $\delta_{i,j} = 1$ si $i = j$; en otro caso, $\delta_{i,j} = 0$. En otras palabras, la convolución del wavelet en su misma escala es uno y con otros que son versiones trasladadas y dilatadas del mismo sistema diádico son cero. Esto completa la *DWT* y permite la regeneración completa de la señal original. Para series de tiempo discretas s_i , donde s_i ocurre en un tiempo discreto i , la *DWT* diádica se escribe de la forma descrita por la ecuación 2.13.

$$T_{j,n} = 2^{-j/2} \sum_{i=0}^{N-1} \psi(2^{-j}i - n) s_i \quad (2.13)$$

donde $T_{j,n}$ es el coeficiente wavelet para la wavelet discreta en esa escala $a = 2^j$, y localización $b = 2^j n$. La ecuación anterior considera una serie de tiempo finita, s_i , $i = 0, 1, 2, \dots, N-1$; y N es un entero potencia de dos: $N = 2^J$. Esto da

un rango de j y n de $1 < j < J$ y $0 < n < 2^{J-n} - 1$. En la escala wavelet más larga, a 2^j donde $j = J$ un coeficiente wavelet se requiere para representar toda la señal y por ende un solo coeficiente wavelet se produce. En la escala previa 2^{j-1} , dos coeficientes wavelet cubren la señal y dos coeficientes son producidos y así sucesivamente. Cuando $m = 1$, la escala a es a 2^1 y $2^J/2^1$, o sea 2^{J-1} , o sea $N/2$ coeficientes se requieren para describir la señal en esa escala. El número total de coeficientes wavelet para una serie de tiempo discreta de longitud $N = 2^J$ es entonces $1 + 2 + 4 + 8 + \dots + 2^{J-1}$, otra manera de representarlo se muestra en la ecuación 2.14.

$$\sum_{j=1}^{J-1} 2^j = 2^J - 1 = N - 1 \quad (2.14)$$

El último componente suavizado es la señal media \bar{T} , así, una serie de tiempo de longitud N puede ser descompuesta en N componentes. La *DWT* inversa se puede obtener mediante la ecuación 2.15.

$$s_i = \bar{T} + \sum_{j=1}^J \sum_{n=0}^{2^{j-1}-1} T_{j,n} 2^{j/2} \psi(2^{-j}i - n) \quad (2.15)$$

La energía en cada escala $a = 2^j$ es dada por la ecuación 2.16.

$$E_j = \sum_{n=0}^{2^{j-1}-1} (T_{j,n})^2 \Delta t \quad (2.16)$$

Por lo tanto, la energía total de la señal puede ser encontrada por la suma de los cuadrados de los coeficientes wavelet, ecuación 2.17.

$$E = \left((\bar{T})^2 + \sum_{j=1}^J \sum_{n=0}^{2^{j-1}-1} (T_{j,n})^2 \right) \Delta t = \sum_{i=0}^{N-1} (s_i)^2 \Delta t \quad (2.17)$$

donde Δt = al intervalo de tiempo entre los puntos discretos en la serie de tiempo. Esta expresión de energía wavelet se separa en componentes suavizados \bar{T} y coeficientes wavelet $T_{j,n}$.

El concepto multiresolución consiste en aplicar sistemáticamente la *WT*. Para el caso práctico se utilizan filtros (Plu et al., 2008; González et al., 2005): la función

de escalamiento $\phi(x)$ filtro pasa-bajas h que permite el análisis de baja frecuencia de datos, o sea la aproximación de la señal (ecuación 2.18) y la función wavelet $\psi(x)$ filtro pasa-altas g para el análisis de los componentes de alta frecuencia. Es decir, el detalle de la serie de tiempo que está siendo analizada (ecuación 2.19). Ambas están relacionadas, además son filtros pasa-bandas (Percival y Walden, 2000).

$$A_{j,t} = \sum_{l=0}^{L-1} h_l A_{j-1, 2t+1-l \bmod N_{j-1}} \quad (2.18)$$

$$D_{j,t} = \sum_{l=0}^{L-1} g_l A_{j-1, 2t+1-l \bmod N_{j-1}} \quad (2.19)$$

donde $t = 0, 1, \dots, N_j - 1$, $A_{j,t}$ es la aproximación de la señal en la escala m posición diádica t , $D_{j,t}$ es el detalle para los mismos parámetros. L es la longitud del filtro y el índice $(j - 1, 2t + 1 - l \bmod N_{j-1})$ significa el submuestreo y remuneración diádica y la función \bmod es el módulo aritmético para realizar la convolución. El proceso de reconstrucción es la transformada inversa, ecuación 2.20.

$$A_{j-1,t} = \sum_{l=0}^{L-1} h_l A_{j,t+l \bmod N_{j-1}}^{\hat{}} + \sum_{l=0}^{L-1} g_l D_{j,t+l \bmod N_{j-1}}^{\hat{}} \quad (2.20)$$

El símbolo $\hat{}$ indica que se encuentra en etapa de reconstrucción.

2.2.1.2.1. Máxima Superposición

La *MODWT* no es una transformada ortonormal, el procedimiento para llevarla a cabo es similar al desarrollado por el algoritmo de Mallat. Mayor información se puede encontrar en el trabajo de Percival y Walden, (2000). Las descomposiciones de aproximación y detalle se calculan con las ecuaciones 2.21 y 2.22 respectivamente.

$$\tilde{A}_{j,t} = \sum_{l=0}^{L-1} \tilde{h}_l \tilde{A}_{j-1, t-2^{j-1}l \bmod N} \quad (2.21)$$

$$\tilde{D}_{j,t} = \sum_{l=0}^{L-1} \tilde{g}_l \tilde{A}_{j-1,t-2^{j-1}l \bmod N} \quad (2.22)$$

donde $t = 0, 1, \dots, N - 1$. El símbolo \tilde{A} es la aproximación del algoritmo de la *MODWT*, \tilde{D} es el detalle. $\tilde{h}_l = h_l/\sqrt{2}$ y $\tilde{g}_l = g/\sqrt{2}$ son los filtros pasa bajas y pasa altas respectivamente y consisten en los filtros del algoritmo de Mallat divididos entre $\sqrt{2}$ con el propósito de conservación de la energía. La señal original puede ser recuperada usando la transformación inversa mediante la ecuación 2.23.

$$\tilde{A}_{j-1,t} = \sum_{l=0}^{L-1} \tilde{h}_l \tilde{A}_{j,t+2^{j-1}l \bmod N}^\uparrow + \sum_{l=0}^{L-1} \tilde{g}_l \tilde{D}_{j,t+2^{j-1}l \bmod N}^\uparrow \quad (2.23)$$

2.2.2.2.1. El algoritmo de Mallat

A fin de comprender el concepto de análisis Multiresolución basado en el algoritmo de Mallat es muy útil representar a la *DWT* como un trapecio, tal como se muestra en la figura 2.4. La base mayor del trapecio es la señal original, con las columnas C . Cada nivel del trapecio, que es sólo accesible desde el nivel inmediatamente inferior, es una aproximación a la señal original. Al bajar por el trapecio la escala aumenta y las series sucesivas tienen una aproximación con resolución más tosca. En la j -ésima, la aproximación de la serie $C/2^j$ columnas porque es una *WT* diádicas donde se aplica con submuestreos o decimaciones (Mallat, 1989).

Estas series de aproximación se calculan utilizando funciones relacionadas con la ampliación de la función wavelet madre $\psi(x)$. (Daubechies, 1988; Mallat, 1989). La diferencia entre la información de dos niveles sucesivos de la pirámide, por ejemplo, entre la serie original s^j a una resolución 2^j en la aproximación de la serie s^{j-1} a una resolución 2^{j-1} viene dada por la *WT*, y se calcula utilizando las funciones wavelet. El coeficiente Wavelet de la serie recoge el detalle s^{j-1} , que se pierde entre las señales s^j y s^{j-1} estos coeficientes contienen las características y con tamaños comprendidos entre la resolución 2^j y 2^{j-1} (algoritmo *DWT* no redundante). Si la señal original tiene C columnas, la aproximación y el coeficiente de wavelet de las series obtenidas

aplicando esta descomposición Multiresolución tiene en el siguiente nivel $C/2^j$ columnas. Cuando la WT inversa se aplica, la señal original s^j puede reconstruirse exactamente a partir de la aproximación de serie A_2^{j-1} y el coeficiente wavelet de detalle D_2^{j-1} .




Figura 2.4. Representación del algoritmo de descomposición wavelet de Mallat

Como ya se mencionó, el número de parámetros de estos filtros, y el valor de estos parámetros dependen de la función wavelet madre utilizada en el análisis. Se presentan en las fórmulas 2.24 y 2.25 los filtros h y g respectivamente, y se toma como ejemplo los coeficientes de la función de escalamiento y función wavelet de Daubechies de orden cuatro, o sea con base en cuatro coeficientes. En el Apéndice B se muestra como se obtienen los coeficientes de escalamiento y wavelet.

$$h = \left\{ \frac{1 + \sqrt{3}}{4\sqrt{2}}, \frac{3 + \sqrt{3}}{4\sqrt{2}}, \frac{3 - \sqrt{3}}{4\sqrt{2}}, \frac{1 - \sqrt{3}}{4\sqrt{2}} \right\} \quad (2.24)$$

$$g = \left\{ \frac{1 - \sqrt{3}}{4\sqrt{2}}, \frac{-3 + \sqrt{3}}{4\sqrt{2}}, \frac{3 + \sqrt{3}}{4\sqrt{2}}, \frac{-1 - \sqrt{3}}{4\sqrt{2}} \right\} \quad (2.25)$$

2.2.2.2.2. El algoritmo 'à trous'

Otro enfoque de la *DWT* es el algoritmo 'à trous' o con agujeros (González et al., 2005). En este caso, el esquema de la descomposición de la señal no puede ser representado con un trapecio como el algoritmo de Mallat, pero si con un rectángulo. La parte superior del rectángulo es la señal original, s^j a una resolución 2^j , con las columnas C . Cada nivel del rectángulo es una aproximación a la señal original, como en el algoritmo de Mallat. Al bajar a través de los niveles de resolución, las aproximaciones de la señales sucesivas tienen una resolución más tosca, pero es el mismo número de elementos de la señal original, tal y como se muestra en la figura 2.5, se puede decir que en contraste con el algoritmo de Mallat, el 'à trous' permite un cambio invariante de la descomposición wavelet discreta, o sea todas las señales de aproximación obtenidas por la aplicación de esta descomposición tienen el mismo número de columnas como la señal original. Esta es una consecuencia del hecho de que estos algoritmos son una transformada no-ortogonal, redundante y sobre muestreada (González et al., 2005), además otra ventaja es el hecho de que la longitud de la señal puede ser diferente a la especificación de la potencia de dos como en el algoritmo de Mallat.

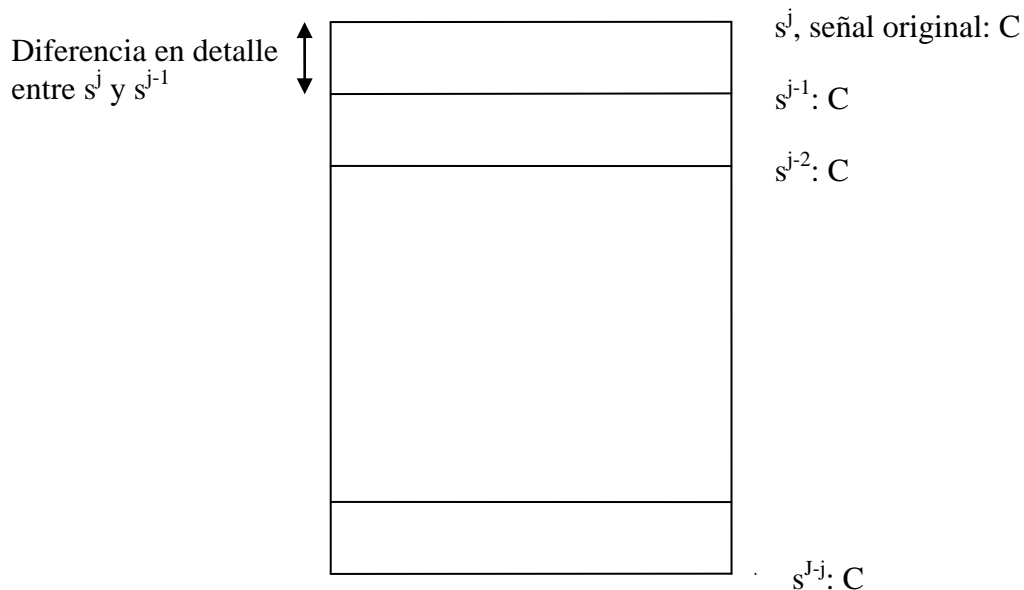


Figura 2.5. Representación del algoritmo de descomposición wavelet 'à trous'

Si un enfoque de descomposición diádica se aplica, la resolución de la aproximación de la señal en el j -ésimo nivel es 2^j no varía. Las aproximaciones de la señal se calculan utilizando funciones de escalamiento. El detalle que se pierde entre las señales s^j y s^{j-1} se recoge en un solo coeficiente wavelet, por esta razón a menudo es llamado wavelet plano. Este wavelet plano, que es globalmente representado por detalles entre las resoluciones 2^j y 2^{j-1} , se calcula como la diferencia entre las señales s^{j-1} y s^j . Cuando La Transformada inversa se aplica, la señal original s^j puede reconstruirse exactamente.

2.2.2.2.3. El algoritmo *MODWT*

El *MODWT* es una modificación de la *DWT*, esta transformada aparece en la literatura con diferentes nombres "undecimated *DWT*", "shift invariant *DWT*", "wavelet frames", "translation invariant *DWT*", "stationary *DWT*", "time invariant *DWT*" y "non-decimated *DWT*" pero es lo mismo que "maximal overlap *DWT*" (Percival y Walden, 2000). En contraste con la *DWT*, la *MODWT* en el nivel j -ésimo para una serie de tiempo es una transformada no-ortogonal altamente redundante. Tiene unas características similares a la '*à trous*', en los niveles de descomposición ya que tienen el mismo número de elementos como la señal original, es no-ortogonal, además que la longitud de la señal puede ser diferente a la especificación de la potencia de dos como en el algoritmo de Mallat.

2.2.2. Redes Neuronales Artificiales

Muy a menudo, en hidrología, los problemas no se entienden claramente o son demasiado mal definidos para un análisis significativo utilizando métodos basados en la física. Incluso cuando esos modelos son disponibles, tienen que confiar en suposiciones. En hidrología existen modelos que son más efectivos cuando los datos sobre las características físicas de la cuenca se encuentran disponibles, este tipo de datos es raramente disponible, incluso en las cuencas de investigación en gran medida instrumentadas y finalmente en el mejor de los casos, la solución es una aproximación. Es evidente que este problema sigue sin

resolverse. Es quizá por esta razón que los métodos alternativos de modelado se siguen buscando (ASCE, 2000b).

Las siguientes son algunas de las razones por las que las *ANN* se han convertido en una herramienta atractiva:

1. Son capaces de reconocer la relación entre las variables de entrada y la salida sin considerar la física explícita del fenómeno.
2. Funcionan bien incluso cuando los conjuntos de entrenamiento contienen ruido y errores de medición.
3. Son capaces de adaptarse a las soluciones con el tiempo para compensar el cambio de circunstancias.
4. Poseen otras características inherentes de procesamiento de información y entrenamiento, además son fáciles de usar.

Las *ANN* tendrían que ser clasificadas como modelos empíricos y tienen muchas características en común con otros métodos de modelación en hidrología. En muchos aspectos, las *ANN* son similares a los modelos basados en regresión en hidrología, excepto que no requieren la especificación de una forma matemática y evitan así tener que resolver complejas ecuaciones en derivadas parciales que finalmente también son aproximaciones. A diferencia de estas técnicas con la *ANN* no hay necesidad de hacer suposiciones sobre la forma matemática de la relación entre la entrada y salida que generalmente son no lineales, y en ocasiones existe presencia de ruido por la naturaleza de las mediciones. Este ruido es manejado por una *ANN* sin pérdida severa de precisión, debido al procesamiento distribuido en la red. Esto, junto con su naturaleza no lineal mejora las capacidades de generación y las hace más versátiles debido a la libertad de elegir ciertos parámetros que hacen que las *ANN* sean atractivas, por lo que es necesario aplicarlas en hidrología y verificar su desempeño.

Las *ANN* son un sistema de procesamiento de información distribuido masivamente en paralelo que tiene ciertas características de rendimiento que se asemejan a las redes neuronales biológicas del cerebro humano. Han sido desarrolladas como una generalización de modelos matemáticos de cognición humana o biología neuronal (ASCE, 2000). Su desarrollo se basa en las

siguientes reglas: primera, el procesamiento de la información se produce en muchos elementos simples llamados nodos, también se conoce como unidades, células o neuronas; segunda, las señales se transmiten a través de enlaces entre los nodos de conexión; tercera, cada enlace de conexión tiene un peso asociado que representa su fuerza de conexión; y cuarta, en cada nodo normalmente se aplica una transformación no lineal llamada función de activación de su entrada neta para determinar su señal de salida. Una *ANN* es caracterizada por su arquitectura que presenta el patrón de conexiones entre sus nodos, su método para determinar los pesos de conexión y la función de activación.

Las *ANN* pueden ser de una sola capa, dos capas o multicapas, estas últimas más conocidas como *backpropagation networks*. Las *ANN* pueden también ser caracterizadas con base en la dirección del flujo de información y procesamiento. Una *feedforward network*, tiene una dirección del flujo en una dirección (hacia adelante) los nodos son generalmente organizados en capas, iniciando en la entrada, una o varias capas ocultas y terminando en la capa de salida. Uno de los métodos más utilizados en hidrología es la *ANN* una *feedforward backpropagation networks (FFBP)* por ejemplo Kim y Valdés (2003); Adamowski (2008); Nourani et al. (2009); Kişi (2009); Partal (2009); González et al. (2008); y, Cisneros y Pelczer (2007) por mencionar algunos. Este método permite que la *FFBP* pueda aprender la asociación esperada entre un patrón de entrada y la salida (Adamowski, 2008).

En la mayoría de las redes, la entrada (que no es la primera capa) recibe las variables de entrada para el problema en cuestión. Esta consta de todas las cantidades que pueden influir en el resultado. La entrada X es transparente y es un medio de proporcionar información a la red. En la figura, 2.6 se muestra un vector de entrada del sistema compuesto por una serie de variables causales que influyen en el comportamiento del sistema. Y es el vector de salida del sistema compuesto por un número de variables resultantes que representan el comportamiento del sistema.

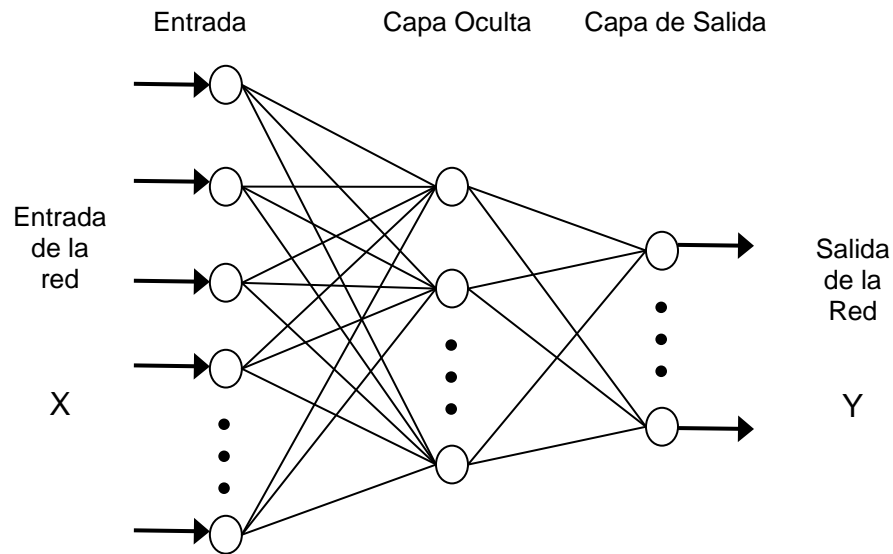


Figura 2.6. Configuración de una ANN alimentada hacia adelante con una entrada y dos capas. Existen diferentes tipos de arquitecturas, en hidrología las más utilizadas son las *FFBP*, las ANN recurrentes (ASCE, 2000a). De aquí en adelante se utilizará la *FFBP* la cual es ampliamente utilizada en hidrología (Kim y Valdés, 2003; Adamowski, 2008; Nourani et al., 2009; Kişi, 2009; Partal, 2009; González et al. 2008; Cisneros y Pelczer, 2007). La arquitectura de la *FFBP* consiste en una entrada n , la capa o capas ocultas m y la capa de salida k (ver figura 2.7).

El número de neuronas de la entrada y la capa de salida son asignadas previamente, para la primera es el mismo número de las variables de entrada, y para la segunda es el número de salidas. Las neuronas ocultas intervienen entre la entrada externa y la salida de la red de una manera útil (Partal, 2009; Kişi, 2009), el objetivo es optimizar el número de neuronas de la capa o capas ocultas (Kişi, 2009), debido a que al fijar la entrada y la capa de salida el desempeño de la *FFBP* depende únicamente de la o las capas ocultas. Se ha demostrado que con una sola capa oculta es suficiente (Beale y Jackson, 1990; Cisneros y Pelczer, 2007), lo que determina el desempeño de la *FFBP* son el número de conexiones (Beale y Jackson, 1990), es decir el desempeño es determinado por el número de neuronas de ésta. La cantidad de estas neuronas se determina generalmente por el procedimiento de prueba y error (ASCE,

2000a; Kişi, 2009; Cisneros y Pelczer, 2007; Adamowsky y Chan 2011; Tiwari y Chaterjee, 2010; Kim y Valdés, 2003).

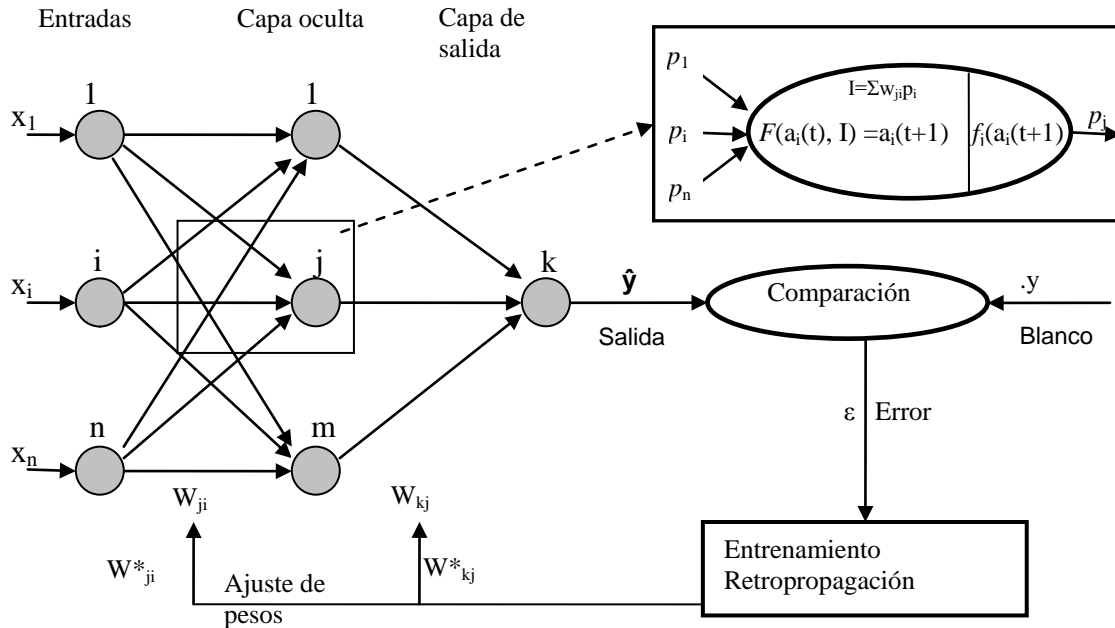


Figura 2.7. ANN FFBP, con una entrada (vector X), dos capas, la oculta y la de salida. Cada círculo representa una neurona que están interconectadas entre si, cada neurona está caracterizada o asociada por un valor numérico denominado valor o estado de activación $a_j(t)$; existe una función de salida f_j , que transforma el estado actual de activación en una señal de salida p_j . Dicha señal es enviada a través de los canales unidireccionales a otras neuronas de la red; en estos canales la señal se modifica de acuerdo con la sinapsis $W_{j,i}$ asociada a cada uno de ellos de acuerdo a determinada regla. Las señales moduladas que han llegado a la neurona j -ésima se combinan entre ellas, generando una entrada total I . Una función de activación F determina el nuevo estado de activación $a_j(t + 1)$ de la neurona. La función de salida f es generalmente la misma que la función de activación.

Una FFBP con una entrada y dos capas, proporciona un mapeo funcional no lineal entre el grupo de variables de entrada y salida. Está basado en una combinación lineal de variables de entrada, que son transformadas por una función de activación no lineal (Kim y Valdés, 2003), por ejemplo la sigmoidea ecuación 2.26.

$$f_h(x) = \frac{1}{1 + e^{-x}} \quad (2.26)$$

La expresión con un valor de salida de una *FFBP* es dada por la ecuación 2.27 (Figura 2.8).

$$\hat{y}_k = f_o \left[\sum_{j=1}^M w_{kj} \cdot f_h \left(\sum_{i=1}^N w_{ji} x_i + w_{jo} \right) + w_{ko} \right] \quad (2.27)$$

donde w_{ji} = peso de conexión de la capa oculta de la i -ésima neurona de la entrada a la j -ésima neurona de la capa oculta; w_{jo} = sesgo de la j -ésima neurona oculta; f_h = función de activación de la capa oculta; w_{kj} = peso de conexión de la capa de salida de la j -ésima neurona de la capa oculta a la k -ésima neurona de la capa de salida; w_{ko} = sesgo para la k -ésima neurona de salida; y f_o = función de activación de la capa de salida. Los pesos son diferentes para cada conexión y sus valores pueden ser cambiados durante el proceso de entrenamiento (Kim y Valdés, 2003).

2.2.2.1. Entrenamiento de la red

El entrenamiento de la red es una calibración, la *ANN* genera un vector de salida $Y = (y_1, y_2, \dots, y_k)$, que lo deseable es que sea lo más cercano posible a un vector objetivo $T = (t_1, t_2, \dots, t_k)$, esto se logra mediante un proceso de entrenamiento (calibración), también llamado de aprendizaje, mediante la modificación de los pesos, el objetivo es encontrar las matrices de pesos óptima W , que minimicen una función de error predeterminado que generalmente es el error cuadrático medio (*MSE*) ecuación 2.28 y en hidrología es muy utilizada la raíz del error cuadrático medio (*RMSE*) ecuación 2.29, (Adamowski y Chan, 2011; Adamowski y Sun, 2010; Shiri y Kisi, 2010; Tiwri y Chatterje, 2010; Besaw et al., 2010; Wu et al., 2010; Remesan et al., 2009; Wu et al., 2009; Adamowski, 2008; Kim y Valdés, 2003).

$$MSE = \frac{\sum_{i=1}^P (y_i - t_i)^2}{N} \quad (2.28)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^P (y_i - t_i)^2}{N}} \quad (2.29)$$

donde P = número de patrones de entrenamiento. Existen principalmente dos tipos de entrenamiento: supervisado y no supervisado. Un algoritmo de entrenamiento supervisado requiere personal externo para guiar el proceso de entrenamiento. Esto normalmente implica un gran número de patrones de entradas y salidas para el entrenamiento. Las entradas son variables causales de un fenómeno y las salidas son variables efecto. Este procedimiento de entrenamiento consiste en el ajuste iterativo de optimización de los pesos de conexión y los valores umbral para cada uno de los nodos. El objetivo principal del entrenamiento es minimizar la función error mediante la búsqueda de un conjunto de pesos de conexión y los valores umbral que causa la ANN, para producir salidas que son iguales o cercanas a las metas (ASCE 2000a). Después que el entrenamiento se completa, se espera que la ANN sea capaz de generar resultados razonables, dadas las nuevas entradas. Por el contrario, un algoritmo de entrenamiento no supervisado se realiza sin personal de supervisión. Durante el entrenamiento, sólo un conjunto de datos de entrada se proporciona a la ANN que adapta automáticamente sus pesos de conexión y se agrupan a esos patrones de entrada en clases con propiedades similares.

2.2.2.2. Algoritmo de Levenberg Marquardt

El algoritmo de *retropropagación* es tal vez el más popular utilizado para el entrenamiento de las ANN (Adamowski y Chan, 2011, ASCEa, 2000). Es esencialmente una técnica de gradiente descendente que minimiza la función error de la red. Cada patrón de entrada del conjunto de datos de entrenamiento se pasa a través de la red desde la capa de entrada a la capa de salida. La salida de la red se compara con la salida objetivo deseada, y se calcula el error (ASCE, 2000a). Este error se propaga hacia atrás a través de la red a cada nodo, y en consecuencia los pesos de conexión son ajustados con base en la ecuación 2.30.

$$\Delta w_{i,j}(n) = -\varepsilon \frac{\partial E}{\partial w_{i,j}} + \alpha \Delta w_{i,j}(n-1) \quad (2.30)$$

donde $\Delta w_{i,j}(n)$ y $\Delta w_{i,j}(n-1)$ = incremento de peso entre el nodo i y j durante el paso enésimo y enésimo-1, o época (iteración). ε y α se llaman tasa de aprendizaje y momentum, respectivamente (ASCE, 2000a; Brahm y Varas, 2003). El factor de momentum puede acelerar el entrenamiento en las regiones muy planas del error de superficie y ayudar a prevenir oscilaciones en los pesos. La tasa de aprendizaje se utiliza para aumentar la posibilidad de evitar que el proceso de entrenamiento quede atrapado en mínimos locales en lugar de mínimos globales (ASCE, 2000a).

El algoritmo de retropropagación implica dos pasos. El primer paso es hacia adelante, en el que el efecto de la entrada se pasa hacia adelante a través de la red para llegar a la capa de salida. Después de que el error se calcula, una segunda etapa se inicia hacia atrás a través de la red. Los errores en la capa de salida se propagan hacia atrás hasta la capa de entrada mediante los pesos que se modificaron de acuerdo a la ecuación 2.30. El algoritmo de retropropagación es un método de primer orden basado en el gradiente descendente, con el vector de dirección que se establece igual al negativo del vector gradiente. En consecuencia, la solución a menudo sigue un camino en zigzag mientras que trata de llegar a una posición de error mínimo, que puede retardar el proceso de entrenamiento. También es posible que el proceso de entrenamiento sea atrapado en el mínimo local a pesar de la utilización de la tasa de aprendizaje (ASCE, 2000a).

La función de entrenamiento utilizada en esta investigación es el algoritmo de Levenberg-Marquardt (LM), por ser una herramienta más poderosa y rápida que el método del gradiente descendente convencional (Tiwari y Chattejee, 2010; Kişi 2009; Brahm y Varas, 2003). El algoritmo (LM) es muy bueno para desarrollar modelos de ANN para pronósticos hidrológicos en términos de significancia estadística y flexibilidad (Adamowski y Chan, 2011), y es una combinación lineal del clásico algoritmo de Newton (Brahm y Varas, 2003). Este algoritmo encuentra una solución óptima de problemas de minimización, además

es clasificado como enfoque de velocidad y precisión de entrenamiento de segundo orden sin tener que calcular la matriz Hessiana, que lo convierte en una técnica de optimización usualmente más rápida y segura (Adamowski y Chan, 2011). Asimismo ha sido utilizada por Adamowski y Karapataki (2010); Tiwari y Chattejee (2010); Wu et al. (2010); Kişi (2010); Remesan et al. (2009); Partal y Kişi (2007); Brahm y Varas (2003); Mehmet et al., (2012), por mencionar algunos. Una vez que la red está entrenada se utiliza para la predicción de otro conjunto de datos de entrada los cuales desconoce, este procedimiento se explica en el apartado 2.2.2.4.

2.2.2.3. El diseño de una ANN

Este paso importante consiste en la determinación de la arquitectura de ANN y la selección de un algoritmo de entrenamiento. Una arquitectura óptima puede considerarse como la obtención de un mejor desempeño en términos de minimización de error, manteniendo una estructura simple y compacta. No existe una teoría unificada para la determinación de este tipo de arquitectura óptima de la ANN (ASCE, 2000a). A menudo, más de una ANN puede generar resultados similares. El número de nodos de entrada y de salida son un problema de dependencia, ellos son iguales a n y m respectivamente. La flexibilidad consiste en elegir el número de capas ocultas y en la asignación del número de nodos a cada una de estas capas. Un procedimiento de prueba y error se aplica generalmente a la decisión sobre la arquitectura óptima (ASCE, 2000a; Cisneros y Pelczer, 2007; Adamowsky y Chan, 2011). Existe un procedimiento de correlación en cascada que puede ser un método eficiente para encontrar la arquitectura óptima (ASCE, 2000a).

2.2.2.4. Agrupamiento de los datos

El agrupamiento de los datos es similar a la calibración, parte integral de la mayoría de los modelados en estudios hidrológicos. El conjunto de datos disponible suele dividirse en tres partes: entrenamiento, validación, y pronóstico (ASCE, 2000a; Cisneros y Pelczer, 2007; Wu et al., 2010; Adamowsky y Chan,

2011), en ocasiones solamente se utilizan el primero y el último grupo de valores (Adamowski y Sun, 2010; Shiri y Kisi, 2010; Nourani et al., 2009; Adamowski, 2008; Kim y Valdés, 2003; Kişi, 2009). El propósito del entrenamiento es determinar el conjunto de pesos de conexión y los umbrales nodales que hacen que la ANN estime salidas que sean lo suficientemente próximas a los valores objetivo. El conjunto de datos correspondiente al entrenamiento se utiliza para lograr este objetivo. Esta fracción de los datos completos que se emplea para el entrenamiento debe contener las pautas suficientes para que la red pueda simular la relación subyacente entre la entrada y la salida adecuada. Este ajuste se puede continuar de forma recursiva hasta que se encuentra un espacio de pesos, lo que resulta en el error de predicción en general más pequeño.

Existe el peligro de exceso de entrenamiento de una red, también conocido como sobreajuste. Esto ocurre cuando los parámetros de red son demasiado ajustados a los datos de conjunto de entrenamiento. Es como si la red, en el proceso de tratar de aprender de la regla subyacente, también ha comenzado a tratar de encajar en el componente de ruido de los datos. En otras palabras, el resultado del sobre entrenamiento en una red es que memoriza los ejemplos individuales, en lugar de las tendencias en el grupo de datos en su conjunto. Cuando esto ocurre, la red funciona muy bien en el conjunto de datos utilizados para el entrenamiento pero muestra una escasa capacidad de predicción, cuando se usan entradas con datos diferentes a los patrones de entrenamiento. Para evitar este tipo de sobreajuste se recomienda, normalmente, un procedimiento de entrenamiento o correlación cruzada o terminación temprana (ASCE, 2000a; Cisneros y Pelczer, 2007; Wu et al., 2009; Tiwari y Chattergee, 2010). El objetivo de este procedimiento es detener el entrenamiento cuando la red comienza a sobreentrenarse. La segunda parte de los datos está reservada para este propósito. Tras el ajuste de los parámetros de la red con cada época, la red se utiliza para encontrar el error de este conjunto de datos. Inicialmente, los errores tanto para el conjunto de datos de entrenamiento y validación bajan, después de que se ha logrado una cantidad óptima de la entrenamiento los errores para el conjunto de entrenamiento sigue

disminuyendo, pero los relacionados con los datos de entrenamiento cruzado empiezan a elevarse. Esta es una indicación de que si el entrenamiento continua es probable que resulte una red sobre ajustada para los datos de entrenamiento. El proceso de entrenamiento se detuvo en este tiempo y el conjunto actual de los pesos y los umbrales se supone que son los valores óptimos. La red está lista para su uso como herramienta predictiva. Si el conjunto de información disponible es demasiado pequeño para el particionamiento, la forma más sencilla para evitar el sobreentrenamiento es detener el entrenamiento cuando el error cuadrado medio deja de disminuir de manera significativa (ASCE, 2000a).

2.2.2.5. Validación de un modelo

Al igual que otros métodos de modelación en hidrología, el desempeño de una ANN entrenada puede ser bien evaluada sometiéndola a nuevos patrones que no ha visto durante su entrenamiento. El rendimiento de la red se puede determinar calculando el porcentaje de error entre los valores esperados y deseados. Además, un diagrama de la salida del modelo en comparación con la respuesta deseada también se puede utilizar para evaluar el rendimiento de ANN. Encontrar los parámetros óptimos de la red es esencialmente un proceso de minimización, es aconsejable repetir el entrenamiento y los procesos de validación varias veces para asegurar que se han obtenido resultados satisfactorios (ASCE, 2000a).

2.2.3. ANFIS

La figura 2.8 se utiliza para explicar el funcionamiento del ANFIS, por simplicidad se asume un FIS con dos entradas x y y con una salida f . Se supone que la regla base contiene dos reglas difusas *if – then* del tipo Takagi y Sugeno (ecuaciones 2.31 y 2.32). Las funciones de los nodos en la misma capa son iguales (Jang, 1993).

$$\text{Regla 1: if } x \text{ es } A_1 \text{ y } y \text{ es } B_1, \text{ then } f_1 = p_1x + q_1y + r_1 \quad (2.31)$$

$$\text{Regla 2: if } x \text{ es } A_2 \text{ y } y \text{ es } B_2, \text{ then } f_2 = p_2x + q_2y + r_2 \quad (2.32)$$

Donde, las entradas x y y al nodo i son $i = 1, 2$. A_i y B_i son niveles lingüísticos

caracterizados por una función de membresía apropiada. Los coeficientes de la combinación lineal en el sistema de inferencia tipo Sugeno son p_i, q_i y r_i , también llamados parámetros consecuentes.

Capa 1 Nodos de entrada, para cada nodo i existe una función de membresía (MF), que arroja un valor lingüístico, ecuación 2.33.

$$O_i^1 = \mu_{A_i}(x) = 1/(1 + ((x - c_i)/a_i)^{2b_i}) \quad (2.33)$$

donde, O_i^1 es la MF de A_i y especifica el grado en que x satisface el cuantificador A_i , el superíndice uno significa la capa. Los parámetros a_i, b_i y c_i (parámetros premisa) son los parámetros de la MF, que cambian su forma, usualmente se utiliza una campana de Gauss con valores de 1 y 0 como máximo y mínimo respectivamente (Jang, 1993).

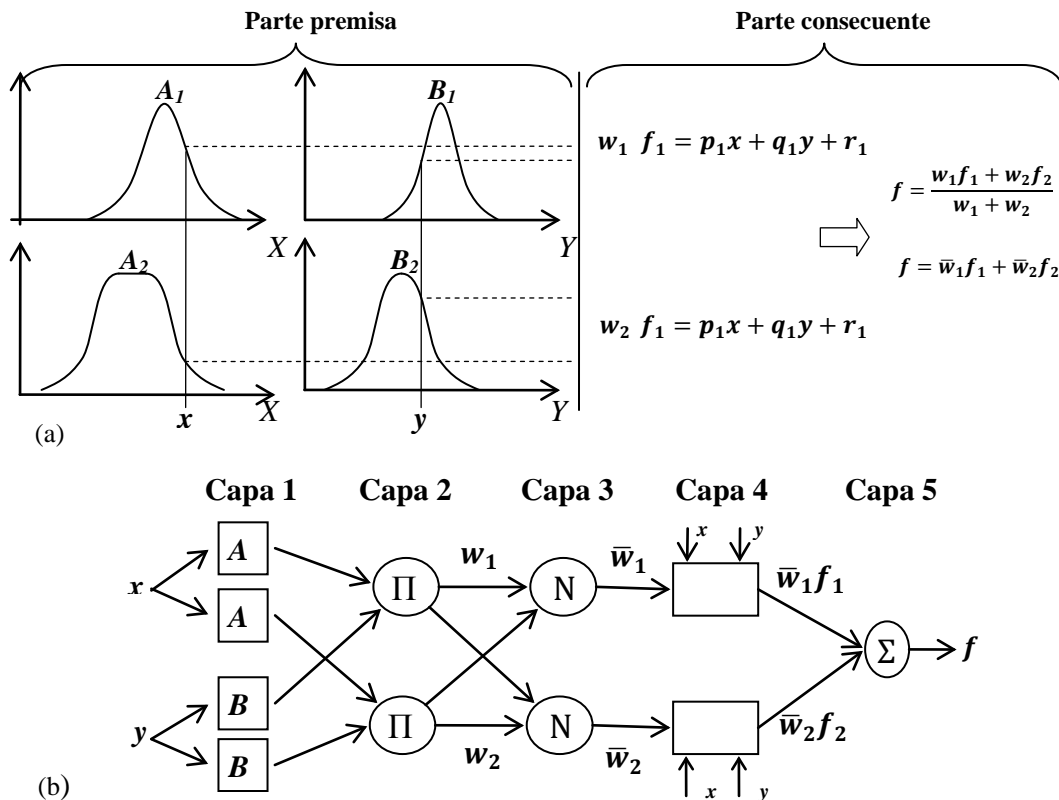


Figura 2.8. a) Modelo difuso de primer orden tipo Sugeno, con dos estradas y dos reglas. b) Arquitectura equivalente de ANFIS.

Capa 2 Reglas de los nodos. Se aplica un operador AND/OR para obtener una salida que es llamada fuerza de disparo de una regla, ecuación 2.34.

$$O_i^2 = w_i = \mu_{A_i}(x)\mu_{B_i}(y), i = 1,2 \quad (2.34)$$

Capa 3 Promedio de los nodos, ecuación 2.35.

$$O_i^3 = \bar{w}_i = w_i/(w_1 + w_2), i = 1,2 \quad (2.35)$$

Calcula el porcentaje de fuerza de disparo de la i -ésima regla en relación a la suma de las fuerzas de disparo de todas las reglas, las salidas de esta capa son llamadas fuerzas de disparo normalizadas.

Capa 4 Nodos consecuentes, ecuación 2.36.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i(p_i x + q_i y + r_i), i = 1,2 \quad (2.36)$$

Es la contribución de la i -ésima regla en relación al total de salidas del modelo.

Capa 5 (Nodos de salida) Es una capa de un solo nodo que calcula la salida final como la suma de todas las señales entrantes, ecuación 2.37.

$$O_i^5 = \sum_i \bar{w}_i f_i = \sum_i w_i f_i / \sum_i w_i, i = 1,2 \quad (2.37)$$

ANFIS utiliza un algoritmo de aprendizaje híbrido, cuando se encuentra en el recorrido hacia adelante la señales siguen hasta la capa cuatro y los parámetros consecuentes son estimados por el método de los mínimos cuadrados. En el recorrido hacia atrás, las tasas de error se propagan en ese sentido y los parámetros premisa son actualizados por el método del gradiente descendente. Se puede encontrar más información en Jang (1993).

2.2.4. Indicadores Caóticos

En este trabajo se utilizan parámetros estadísticos comúnmente utilizados en la literatura además de dos indicadores caóticos que son los exponentes de Hurst y Lyapunov, y se emplean con el propósito de identificar la predictibilidad de la serie de tiempo estudiada. A continuación se presenta una síntesis de estos métodos:

2.2.4.1. Exponente de Hurst

Un camino para cuantificar la correlación que existe en una serie de tiempo es el análisis del rango reescalado (R/σ). Este rango es desarrollado por Harold Edwin Hurst (1900-1978) quien pasó 62 años en Egipto como miembro del

servicio civil Británico, estudiando la dependencia de largo plazo de los niveles del agua del ríos entre ellos el Nilo, además en presas. Para el cálculo del exponente de Hurst, se utiliza la diferencia con respecto de la media \bar{X} , como se muestra en la ecuación 2.38.

$$Y_\rho = \sum_{i=1}^n (X_i - \bar{X}) \quad (2.38)$$

donde Y_ρ es la suma de las desviaciones acumulativas de la serie de tiempo X con elementos $x_1, x_2, x_3, \dots, x_n$ e i es el contador del elemento de la serie de tiempo que tiene longitud n y ρ es el tamaño de la muestra o pasos de un camino aleatorio en una dimensión.

En la ecuación 2.39 se calcula el rango.

$$R = \text{Max } Y_\rho - \text{Min } Y_\rho \quad (2.39)$$

donde R es el rango, que es diferencia entre el valor máximo Max y mínimo Min de las desviaciones acumulativas en un tamaño de paso ρ .

La convergencia del rango reescalado R/σ , donde σ es la desviación estándar de X , es aproximadamente $C\rho^H$, C es una constante y H es el exponente de Hurst (Hurst et al. 1965), que mide el suavizado de la serie de tiempo. En la ecuación 2.40 se muestra la ecuación del rango reescalado en la convergencia.

$$\frac{R}{\sigma} = (C\rho)^H \quad \text{cuando } \rho \rightarrow \infty \quad (2.40)$$

Mediante simulaciones Hurst et al. (1965) encontró que $C = \pi/2$. y la ecuación 2.40 se convierte en la 2.41.

$$\frac{R}{\sigma} = \left(\frac{\pi\rho}{2}\right)^H \quad (2.41)$$

Las siguientes consideraciones Hurst et al. (1965) son comúnmente encontradas en la literatura, por ejemplo (Ramachandra y Bhattacharya, 1999; Ma y Liu, 2007; Clinton 2008; Pérez y Torra, 2003; Rehman y Siddiqi, 2007; entre otros), aquí se hace una síntesis de todas ellas:

1. Valores de H están en el rango $0 < H < 1$ y son llamados movimiento Browniano fraccional o fBm . Una secuencia de valores X_ρ sin correlación

- produce movimiento Browniano y $H = 1/2$. Un valor de H cercano a $1/2$ indica que una serie de tiempo es aleatoria con una distribución de probabilidad de tipo Poisson, es decir, el signo de dx/dt cambia de manera aleatoria lo que implica que no hay una correlación.
2. Valores con rango $1/2 < H < 1$ se conocen como *Lévy flights*, implica serie de tiempo persiste o correlación positiva, donde la tendencia de la trayectoria continúa en su dirección actual, por lo tanto produce una mejoría en la difusión (la evolución hacia una dispersión uniforme en todo el espacio de las fases), es decir los valores cercanos a $H = 1$, el signo de dx/dt tiende a ser constante y este se mantiene en largos periodos de tiempo, la serie es periódica e implica una serie fractal.
 3. Los valores con $0 \leq H < 1/2$ indican antipersistencia de la serie de tiempo o correlación negativa. Valores cercanos a cero muestran que la trayectoria tiende a volver al punto de procedencia y de este modo suprime la difusión, el signo de dx/dt tiende a ser oscilatorio, estos valores son característicos del ruido blanco.

Hurst et al. (1965) notó que muchos procesos naturales, tales como descarga de ríos, sedimentos de lodo, tienen $H = 0.73 \pm 0.09$ y por lo tanto tienen que ser considerados como procesos de memoria larga. *fBm* es un proceso no estacionario, su Y^2 incrementa con el tiempo sin límite, por esta razón se utiliza R/σ . Aplicado logaritmos base dos a la ecuación 2.41 se obtiene la 2.42:

$$\log_2\left(\frac{R}{\sigma}\right) = \log_2\left(\frac{\pi}{2}\right) + H \log_2\left(\frac{1}{\rho}\right) \quad (2.42)$$

Para calcular el rango escalado, primeramente se divide el conjunto de datos X que preferentemente tendrá una longitud $n = 2^u$ donde u es el máximo exponente para diferentes tamaños de la muestra o pasos ρ . ($0 \leq \rho \leq u$), cada subconjunto tendrá una longitud n_u ($1 \leq n_u \leq 2^u$). De acuerdo a la ecuación 2.42 la pendiente de la recta en ejes logarítmicos base dos es el exponente de Hurst H .

Por otra parte se comenta que existen otros métodos matemáticamente más complejas para encontrar el exponente de Hurst como el modelo llamado *Fractional Gaussian Noise (FGN)*, de acuerdo a Ramachandra y Bhattacharya (1999) el método del rango reescalado (R/σ) para series hidrológicas es un método robusto y es recomendado para su uso, *FGN* no es robusto y no es recomendado utilizarlo por los autores antes mencionados.

2.2.4.2. Exponente de Lyapunov

De acuerdo a la Real Academia Española caos es un comportamiento aparentemente errático e impredecible de algunos sistemas dinámicos, aunque su formulación matemática sea en principio determinista. O sea, es un fenómeno aperiódico de comportamiento de largo plazo acotado.

El caos es un tema en el campo de la dinámica no-lineal, que a su vez es parte de los sistemas dinámicos. Un sistema dinámico está comprendido en el tiempo, puede ser estocástico cuando evoluciona de acuerdo a procesos aleatorios, o determinísticos en el caso que el futuro está únicamente determinado por los eventos pasados de acuerdo a algunas reglas o fórmulas matemáticas (Clinton, 2008).

Un atractor es un conjunto compacto hacia el que todas las soluciones del sistema dinámico se aproximan o convergen cuando el tiempo se hace grande (Canan y Yilmaz, 2011). Existen muchos ejemplos de atractores, el más sencillo podría ser en el área del análisis numérico clásico para encontrar raíces o ceros en una función real, de ellos un método sensible a su punto de inicio es el de Newton o Newton-Raphson que dependiendo de la función converge o diverge (también sucede con el método de la secante que es una variación del Newton-Raphson), a la gráfica de convergencia se le podría considerar como un atractor. Existen atractores mucho más complejos como el que a continuación se describe.

El atractor de Lorenz, concepto introducido por Edward Lorenz (1963), es un sistema dinámico determinístico tridimensional no lineal derivado de las ecuaciones simplificadas de rolos de convección que se producen en las

ecuaciones dinámicas de la atmósfera terrestre. Para ciertos valores de los parámetros a , b y c el sistema exhibe un comportamiento caótico y muestra lo que actualmente se llama un atractor extraño. Las ecuaciones que gobiernan el atractor de Lorenz son la 2.43, 2.44 y 2.45 (Lorenz, 1963):

$$\frac{dx}{dt} = a(y - x) \quad (2.43)$$

$$\frac{dy}{dt} = x(b - z) - y \quad (2.44)$$

$$\frac{dz}{dt} = xy - cz \quad (2.45)$$

donde a se conoce como número de Prandtl y b como número de Rayleigh. Tanto a, b y $c > 0$, pero usualmente $a = 10$, $c = 8/3$ mientras b varía. El sistema exhibe un comportamiento caótico para $b = 28$ pero muestra órbitas periódicas para otros valores de b (ver figura 2.9).




Figura 2.9. Atractor de Lorenz, con $a = 10$ número de Prandtl, $b = 28$ número de Rayleigh y $c = 8/3$, $dt = 0.01$. Edward Lorenz (1963).

El exponente de Lyapunov proporciona el grado de predictibilidad de un sistema y describe la sensibilidad de dependencia que existe sobre las condiciones iniciales, el número de estos exponentes es igual a la dimensión del espacio de fase. O sea, describe la tasa de divergencia de las trayectorias en el espacio de fase y por lo tanto puede ser utilizado para la identificación de caos.

En una dimensión $X_{n+1} = f(X_n)$, si dos puntos cercanos iniciales X_0 y $X_0 + \Delta X_0$, después de una iteración los puntos son separados por:

$$X_1 = f(X_0 + \Delta X_0) - f(X_0) \cong \Delta X_0 f'(X_0) \quad (2.46)$$

donde $f' = df/dX$. Por definición el exponente de Lyapunov local λ en X_0 es:

$$e^\lambda = |\Delta X_1 / \Delta X_0| \quad (2.47)$$

o

$$\lambda = \ln |\Delta X_1 / \Delta X_0| \cong \ln |f'(X_0)| \quad (2.48)$$

donde $|\Delta X_1 / \Delta X_0|$ es el exponente de Lyapunov local, y es una medida de estiramiento entre $X = X_0$. El valor absoluto asegura que el número de Lyapunov sea positivo de modo que su logaritmo (exponente de Lyapunov) sea un número real. Si $\Delta X_1 / \Delta X_0$ es negativo significa que dos puntos cercanos intercambian su orden (el más largo se convierte en el más pequeño y viceversa) en una iteración. Conociendo como el exponente de Lyapunov local varía en el espacio permite identificar regiones de un atractor con buena o mala predictibilidad para errores iniciales pequeños. Se define también como factor de no-uniformidad como la desviación estándar de la distribución del exponente de Lyapunov local. Para obtener el exponente de Lyapunov global, promedio de la ecuación 2.49, para repetidas iteraciones, se obtiene la ecuación 2.49 (Uesugui et al., 2000; Canan y Yilmaz, 2011).

$$\lambda = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{n=0}^{N-1} \ln |f'(X_n)| \quad (2.49)$$

Sí la órbita es periódica, solamente se necesita promediar sobre un periodo a la vez debido a que la órbita está en el atractor. El promedio del factor de estiramiento e^λ es el exponente de Lyapunov global, este último exponente

determina la tasa exponencial promedio de separación en dos condiciones iniciales cercanas, o el promedio de estiramiento del espacio. La existencia de un exponente de Lyapunov dominante positivo indica caos (Sen et al., 2007; Martínez et al., 2007; Giannerini y Rosa, 2004; Kantz y Schreiber, 1997; Reiss et al., 2008; Lana et al., 2010; Canan y Yilmaz, 2011; Ma y Liu, 2007) y uno negativo indica ciclos periódicos o puntos fijos.

De acuerdo a Clinton (2008) el primer algoritmo para estimar el exponente de Lyapunov es propuesto por Wolf et al. (1985). Desafortunadamente requiere de mucho cuidado cuando se utiliza y se pueden obtener resultados equivocados. Este algoritmo no permite probar una divergencia exponencial, solo asume su existencia y por lo tanto produce un exponente finito para datos estadísticos, cuando el exponente verdadero es infinito, por eso ya no se utiliza en la reconstrucción del espacio de fase. Existen otras clase de algoritmos que también implican la aproximación de dinámica determinística fundamental y son muy eficientes si los datos permiten una buena aproximación de la dinámica (Kantz y Schreiber, 1997).

En este trabajo se utiliza el algoritmo de Kantz (1994), porque es un método robusto aplicable a sistemas sin suavizado (Kantz, 1994; Kantz y Schreiber, 1997; Sen et al. 2007). Esta prueba es diseñada para una divergencia exponencial de trayectorias cercanas y por lo tanto permite decidir si realmente tiene sentido calcular los exponentes de Lyapunov dado un grupo de datos.

En este método el exponente de Lyapunov es el promedio de la tasa de divergencia local sobre la totalidad de los datos. Los datos experimentales son generalmente contaminados por ruido, su influencia puede ser minimizada usando un apropiado promedio estadístico cuando se calcula el exponente. Para obtener el promedio exponencial del crecimiento de las distancias se escoge un punto x_{n_0} de la serie de tiempo en el espacio introducido y se seleccionan todos los puntos vecinos con distancia más pequeña que ε . Se calcula el promedio de las distancias de todos los puntos cercanos al de referencia de la trayectoria como una función del tiempo relativo. El logaritmo natural de la distancia promedio en el tiempo Δn es cierta tasa efectiva de expansión sobre el lapso de

tiempo Δn (mas el logaritmo de la distancia inicial) contiene todas las fluctuaciones determinísticas debidas a la proyección y dinámica. Repitiendo este procedimiento para muchos valores de n_0 , las fluctuaciones de las tasas de expansión efectivas se promediarán. Por lo tanto se pueden calcular por la ecuación 2.50 (Kantz y Schreiber, 1997; Giannerini y Rosa, 2004).

$$X(\Delta n) = \frac{1}{N} \sum_{n_0=1}^N \ln \left(\frac{1}{|U(x_{n_0})|} \sum_{x_n \in U(x_{n_0})} |x_{n_0+\Delta n} - x_{n+\Delta n}| \right) \quad (2.50)$$

donde los puntos de referencia x_{n_0} son vectores introducidos usualmente $U(x_{n_0})$ en la vecindad de x_{n_0} con diámetro ϵ . El último elemento x_{n_0} es x_{n_0} donde $x_{n_0+\Delta n}$ esta afuera del lapso de tiempo cubierto por el vector de retraso x_{n_0} . Desde un punto previo no se puede conocer la dimensión de introducción mínima m ni la óptima distancia ϵ , por lo tanto se debe calcular $X(\Delta n)$ para una variedad de valores de m y ϵ . El tamaño de las vecindades debería ser lo más pequeña posible pero suficientemente larga tal que el promedio sobre cada punto de referencia tenga al menos unos pocos puntos vecinos. En otro caso sistemáticamente podría ignorar ciertas partes del atractor y así calcular un valor equivocado.

Si para algunos rangos de Δn la función $X(\Delta n)$ exhibe un incremento lineal robusto, su pendiente es una estimación del máximo exponente de Lyapunov λ (Kantz y Schreiber, 1997).

Capítulo III
Métodos

3.1. Introducción

La información climatológica del estado de Baja California es escasa en comparación con la existente en el estado de California EUA. En Baja California hay 88 estaciones climatológicas de las cuales 7 son automáticas administradas por la CONAGUA y 17 automáticas que pertenecen a la SEFOA, el resto de las estaciones son manuales con registros diarios. En California EUA, hay 1213 (NOAA, 2008) de las cuales 12 son radares meteorológicos de última generación. Según Pizarro (1993) la *World Meteorological Organization* estableció que para la existencia de una red pluviométrica con buena cobertura, en terrenos montañosos se debe contar con al menos un pluviómetro cada 25 km², mientras que en terrenos planos debe disponerse de uno cada 50 km², de acuerdo a este criterio y considerando un promedio en Baja California deberían existir al menos 2797 estaciones, y en California 11157. Esto equivale a un déficit de 2709 en Baja California y un exceso en California de 414015 estaciones, considerando que el radar equivale a una estación por kilómetro cuadrado y tiene un alcance de 360 km. Sin embargo en la RH01 solamente existen 33 estaciones pluviométricas de las cuales 15 presentan registros de más de 50 años, más 17 estaciones automáticas que inician sus registros entre los años 2000 y 2003 (deducciones propias con información CONAGUA, 2011 y Quintas e IMTA, 2000). Las estaciones automáticas están en los principales valles agrícolas y presas, por su parte las estaciones pluviométricas están localizadas generalmente sobre las vías principales de comunicación terrestre. Por eso es importante potencializar la valiosa información.

3.2. Algoritmos híbridos desarrollados

i. En primer lugar se elabora un inventario de las estaciones climatológicas de la región, indicando la calidad de la información y el periodo de vigencia de cada estación de acuerdo a su fuente: Comisión Nacional del Agua, Secretaría de Fomento Agropecuario, Sistema de Protección Civil. La calidad se mide en relación al periodo de medición, horarias diarias, semanal, mensual, anual, etc.,

el tiempo de registro, información que contienen como: periodos de registro, inclusión de datos con lluvias extremas, si tienen datos faltantes. Mediante un análisis de la información se escoge una estación y su periodo para el estudio. Se elige solamente una serie de tiempo debido a que el objetivo es implementar el método propuesto con el propósito de evidenciar el aporte científico de la investigación.

ii. Posteriormente se procederá a elaborar un análisis visual de los coeficientes wavelet de la *CWT*, mediante la wavelet madre de Morlet (Torrence y Compo, 1998) que de acuerdo a la literatura es muy bueno para estudiar datos climáticos para el caso continuo, se aplica el concepto multiresolución para el análisis de los escalogramas de la serie de tiempo considerada. Con esta técnica se identifican estructuras coherentes tales como: discontinuidades, efectos de borde, periodicidad de grupos.

iii.- De la totalidad de la serie se determinan los tres grupos de valores para el agrupamiento de los datos entrenamiento, validación y pronóstico.

iv.- Se grafica la serie y se determinan los valores estadísticos e indicadores caóticos para la serie de tiempo a analizar con el propósito de determinar el tipo de serie. Los valores estadísticos son: la media, el valor máximo, el mínimo, la desviación estándar, el sesgo, coeficiente de autocorrelación para 1, 2, 3, 12 y 24 meses. Los indicadores caóticos son: el exponente de Hurst y el exponente de Lyapunov.

Una vez analizados los grupos de datos se subdividen en dos partes una para ser analizada y otra para ser pronosticada, con el propósito de utilizar dos de los enfoques encontrados en la literatura.

3.2.1. Descomposición con *DWT*

i.- Para la descomposición de la señal se requiere el uso de coeficientes de escalamiento c_k y wavelet b_k , en este trabajo se aplicarán los coeficientes de Haar (que es una particularidad del wavelet de Daubechies) y Daubechies de orden cuatro (*Db4*), para utilizarlos como filtros uno pasa-bajas y otro pasa-altas. El primero es un filtro de suavizado para los datos, el segundo extrae la señal de

detalle en cada escala. Estos valores satisfacen las condiciones mostradas en el Capítulo II, sección 2.2.1.2 como todas las funciones wavelet ortonormales. Además, satisfaciendo estos criterios, se requiere que los wavelet madre sean de soporte compacto, o sea, un número finito de coeficientes de escalamiento N_k , los valores de los coeficientes wavelet b_k dependen de los valores de los coeficientes de escalamiento c_k . En el Apéndice B se desarrolla el método para obtener estos coeficientes.

ii.- La *DWT* con el algoritmo de Mallat se realiza mediante un filtrado de la señal S , la aproximación del primer nivel se iguala a la señal, es decir $A_{j,n} = S_{j,n}$ para el nivel j y posición n . Como $j = 0$ entonces $A_{0,n} = S_{0,n}$, a esto se le conoce como "crimen wavelet". Entonces se le aplican los filtros pasa bajas y pasa altas y se obtienen respectivamente las aproximaciones $A_{j+1,n}$ y los detalles $D_{j+1,n}$ del siguiente nivel $j + 1$, y el proceso se repite de manera sistemática hasta el nivel válido deseado. En la figura 3.1a se muestra un diagrama esquemático del filtrado de los coeficientes de aproximación que producen coeficientes de aproximación y detalle en las sucesivas escalas. El símbolo de submuestreo del dos con la flecha hacia abajo en negritas encerrado en un círculo significa tomar los segundos valores de la señal filtrada. LP y HP son respectivamente los filtros pasa bajas y pasa altas. En la práctica el filtro es desplazado a lo largo una localización a la vez en la señal, por lo tanto el filtrado más submuestreado corresponde a saltar todos los segundos valores como se muestra en la figuras 3.2 y 3.3.

En la *DWT* inversa la aproximación $A_{j+2,n}$ y el detalle $D_{j+2,n}$ son procesados con los filtros invertidos y se obtiene la aproximación de la escala previa $A_{j+1,n}$, el proceso es repetido de manera sistemática hasta llegar a la $A_{0,n}$, ver figura 3.1b. Esta figura es un diagrama esquemático del filtrado de los coeficientes aproximación y detalle que producen los coeficientes de aproximación de las sucesivas escalas más pequeñas. El símbolo de muestreado hacia arriba del dos con la flecha hacia arriba en negritas encerrado en un círculo significa añadir un cero entre todos los segundos valores del vector de entrada en turno. Los

coeficientes de los filtros LP' y HP' son ordenados al revés que sus homólogos usados en la descomposición mostradas en el inciso (a).

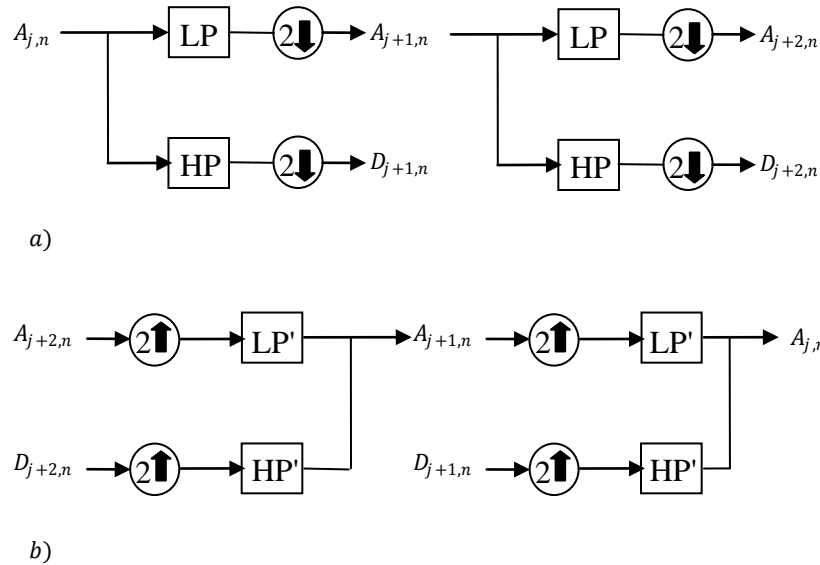


Figura 3.1 Esquema del filtrado de la señal. a) descomposición, b) reconstrucción (Addison, 2002).

La *DWT* se realiza mediante una técnica de convolución, para el desarrollo de esta investigación es muy importante comprender su mecanismo. La figura 3.2 muestra esquemáticamente el desarrollo de la convolución para la obtención de las aproximaciones con el algoritmo de *DWT* Mallat, o sea se utiliza el filtro g con cuatro coeficientes de escalamiento h_l .

En la figura 3.2 se presenta un ejemplo de una secuencia de los cuatro dígitos $1/\sqrt{2} h_l$ se filtrándose a través de la aproximación $A_{0,n}$ en escala $j = 0$ con submuestreos en cada salto. Se obtiene un componente de aproximación en la siguiente escala $j + 1$ y se desliza el filtro pasa bajas utilizando dos saltos en la posición de la aproximación para encontrar el siguiente valor $A_{1,n}$. El submuestreo elimina todos los segundos valores, el diagrama muestra los valores retenidos. Lo importante de este ejemplo es que se utilizan los tres valores siguientes de la aproximación en cada salto para encontrar un valor en la siguiente escala $J + 1$.

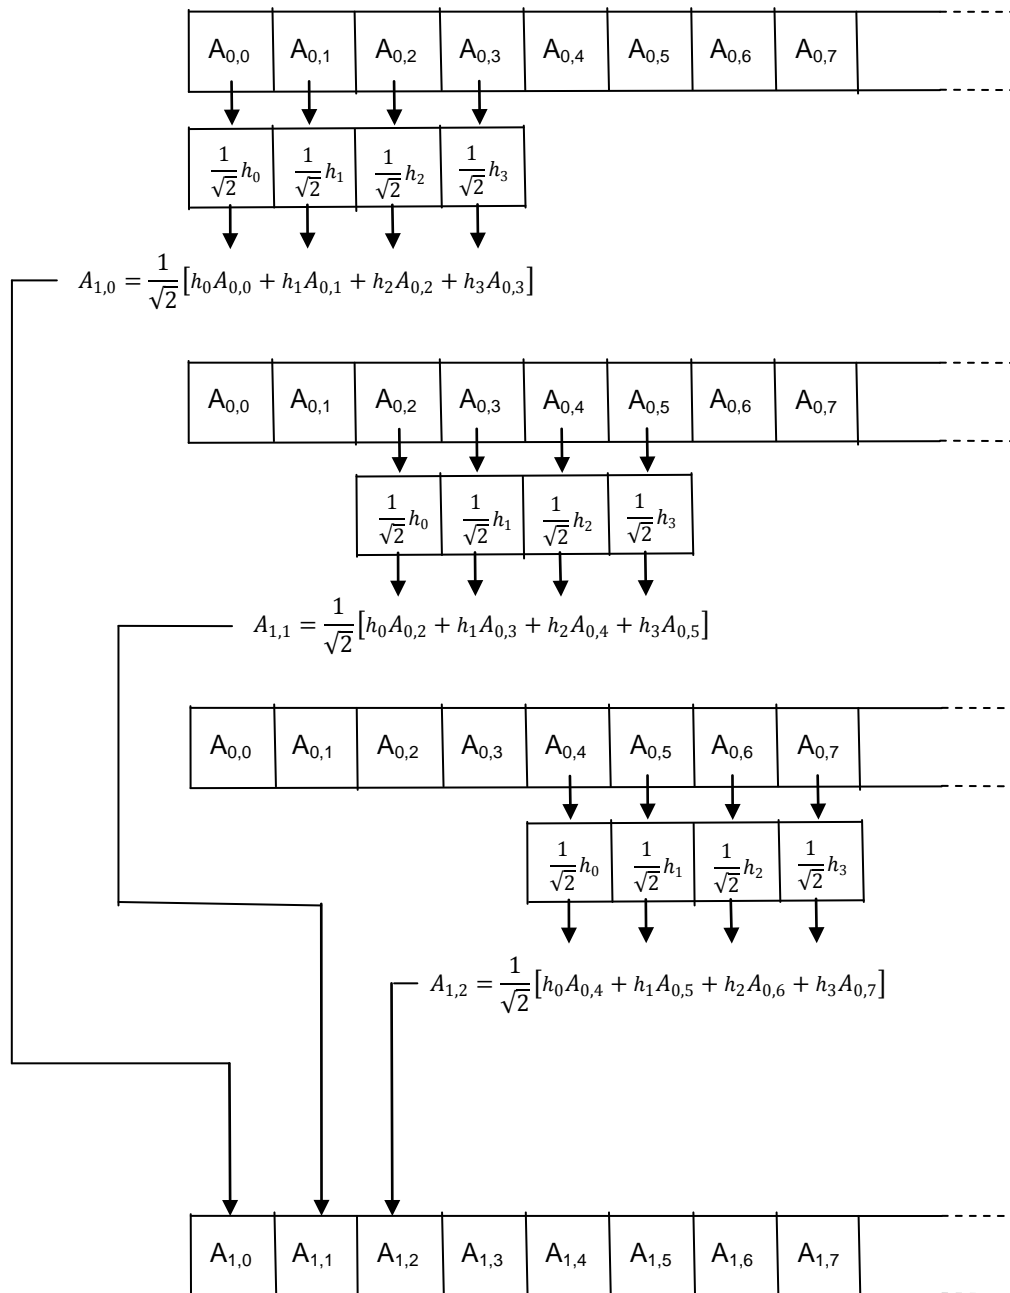


Figura 3.2. Filtrado de descomposición de las aproximaciones con el algoritmo de Mallat.

Para obtener los detalles se realiza un procedimiento similar utilizando los coeficientes wavelet g_l , ver figura 3.3.

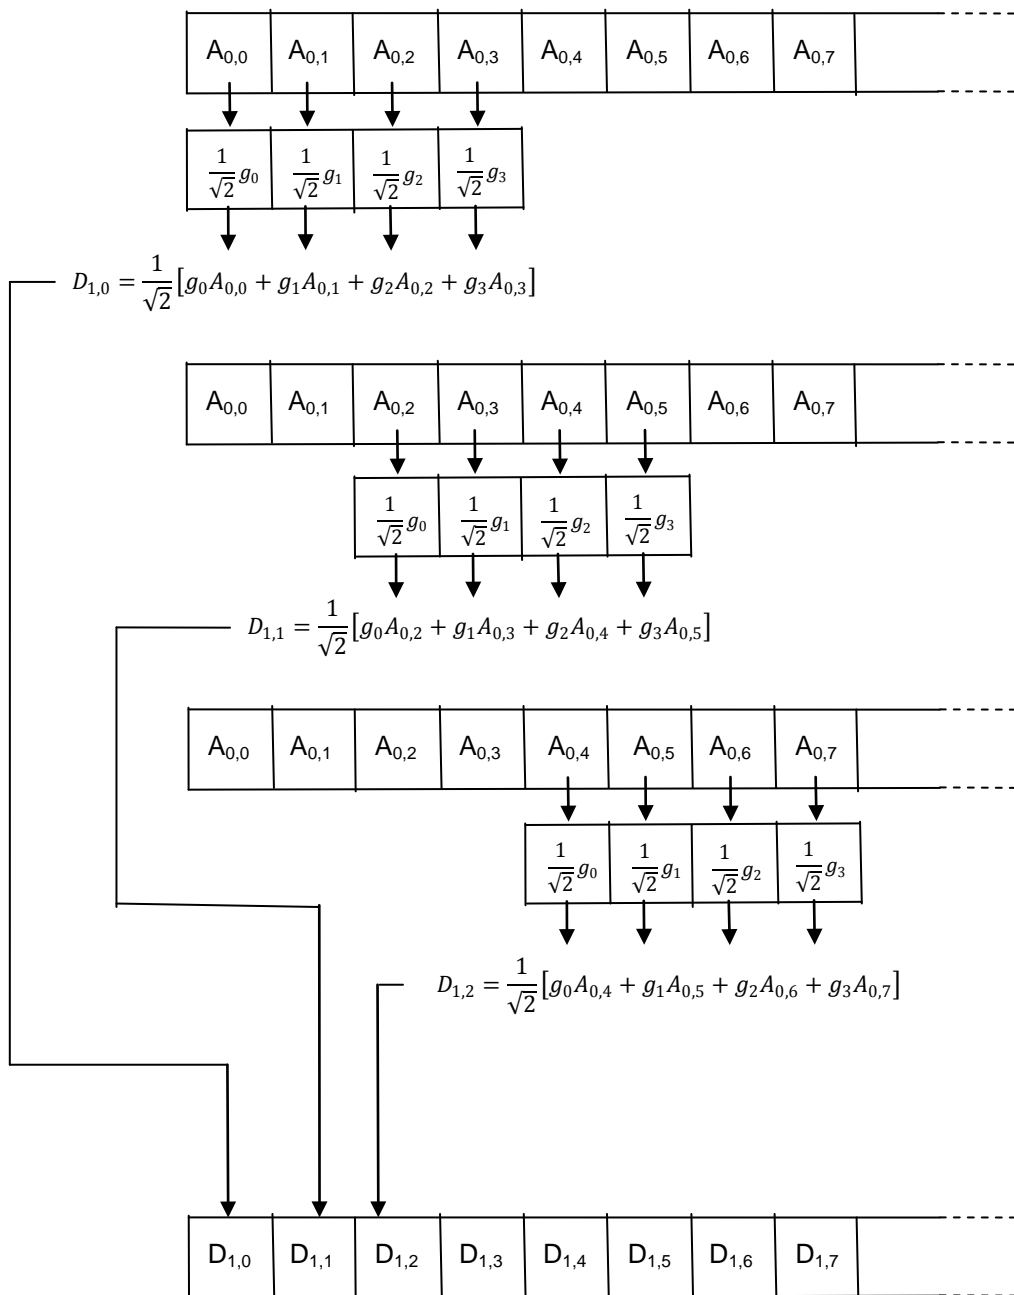


Figura 3.3. Filtrado de descomposición de los detalles con el algoritmo de Mallat.

En el proceso inverso de reconstrucción del algoritmo de Mallat el filtrado es simplemente invertido, por lo cual los componentes de la escala más grande son regresados a través de los filtros. Esto se muestra esquemáticamente en la figura 3.4, los componentes de aproximación y detalle en índice de escala $j + 1$ primero son muestreados hacia arriba, luego se insertan ceros entre los valores

de las aproximaciones y detalles previos. Entonces son pasados a través del filtro pasa bajas y pasa altas. Para lograrlo los coeficientes de los filtros son invertidos en orden y son pasados en reversa a lo largo de la señal modificada por los ceros intercalados. En la figura 3.4 se muestra un ejemplo del filtrado de reconstrucción, donde el componente $A_{5,n}$ es encontrado para la secuencia $A_{j+1,n}$ y $D_{j+1,n}$.

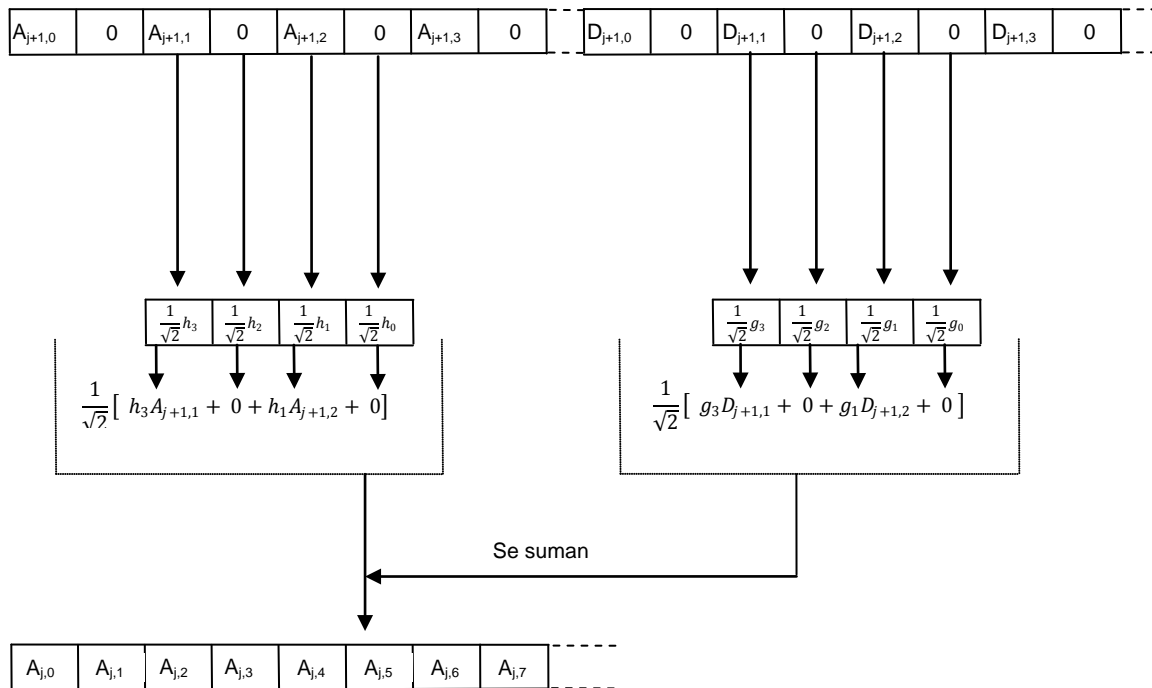


Figura 3.4. Filtrado de la señal en reconstrucción por el algoritmo de Mallat.

Para el caso de la *MODWT* el método de filtrado es similar al de Mallat, la diferencia es simplemente que se omite la parte del submuestreo del proceso de filtrado, o sea cada valor es retenido debido a que el filtro se mueve un paso a la vez. Esto se traduce en el mismo número de coeficientes wavelet de aproximaciones y detalles generados en cada escala, o sea, igual al número de componentes de la señal N . Los filtrados de aproximación y detalles se esquematizan en las figuras 3.5 y 3.6, respectivamente, estas descomposiciones son similares al algoritmo de Mallat pero sin submuestreo.

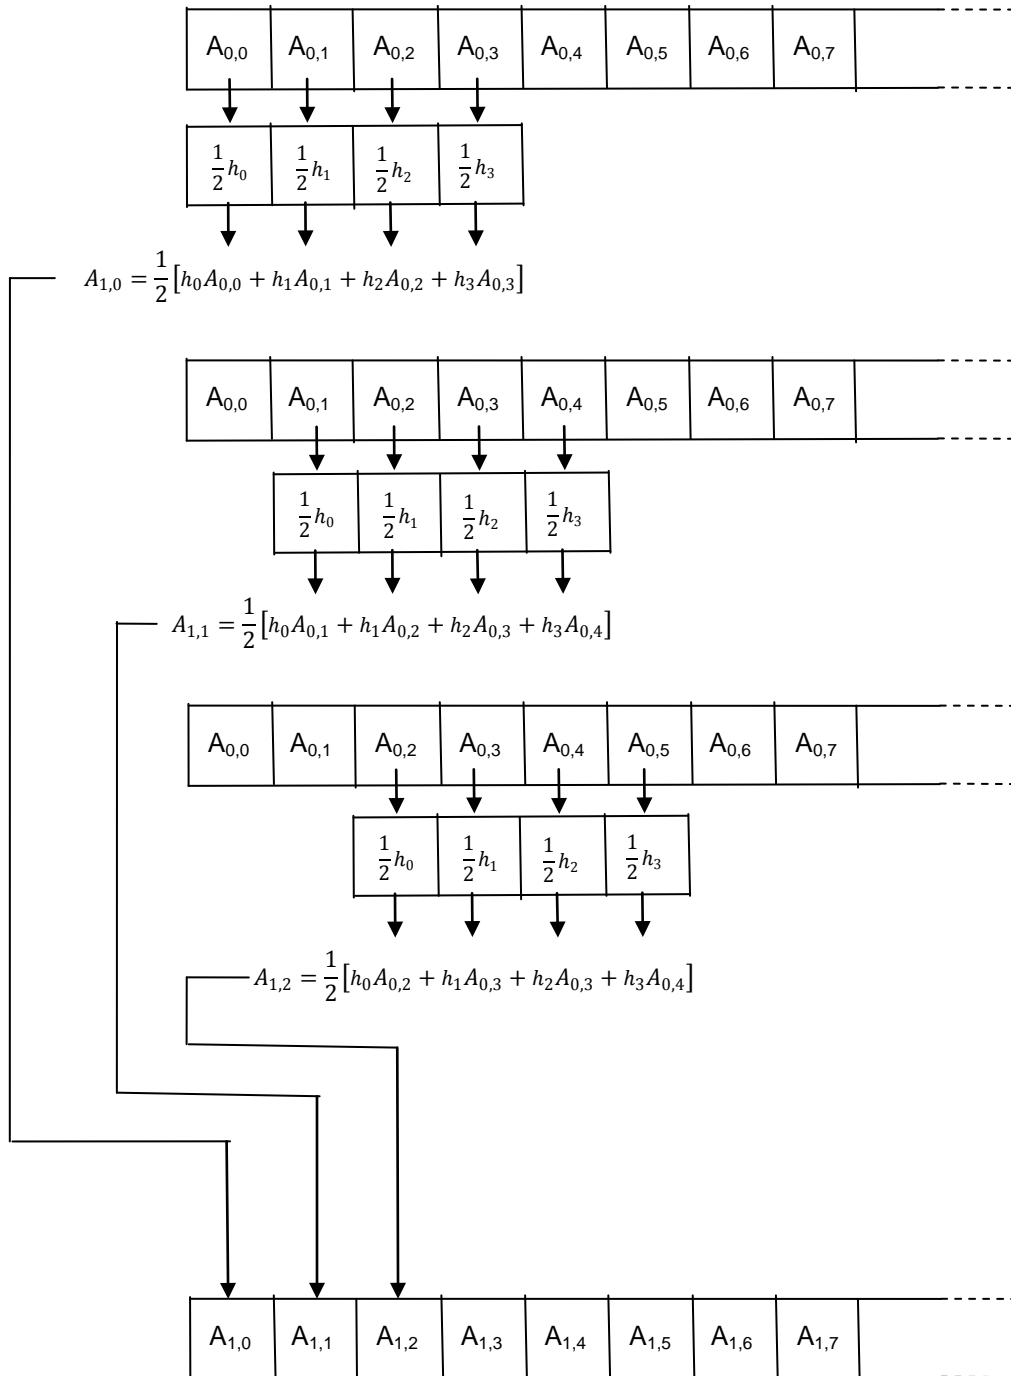


Figura 3.5. Filtrado de descomposición de la aproximación con el algoritmo de *MODWT*.

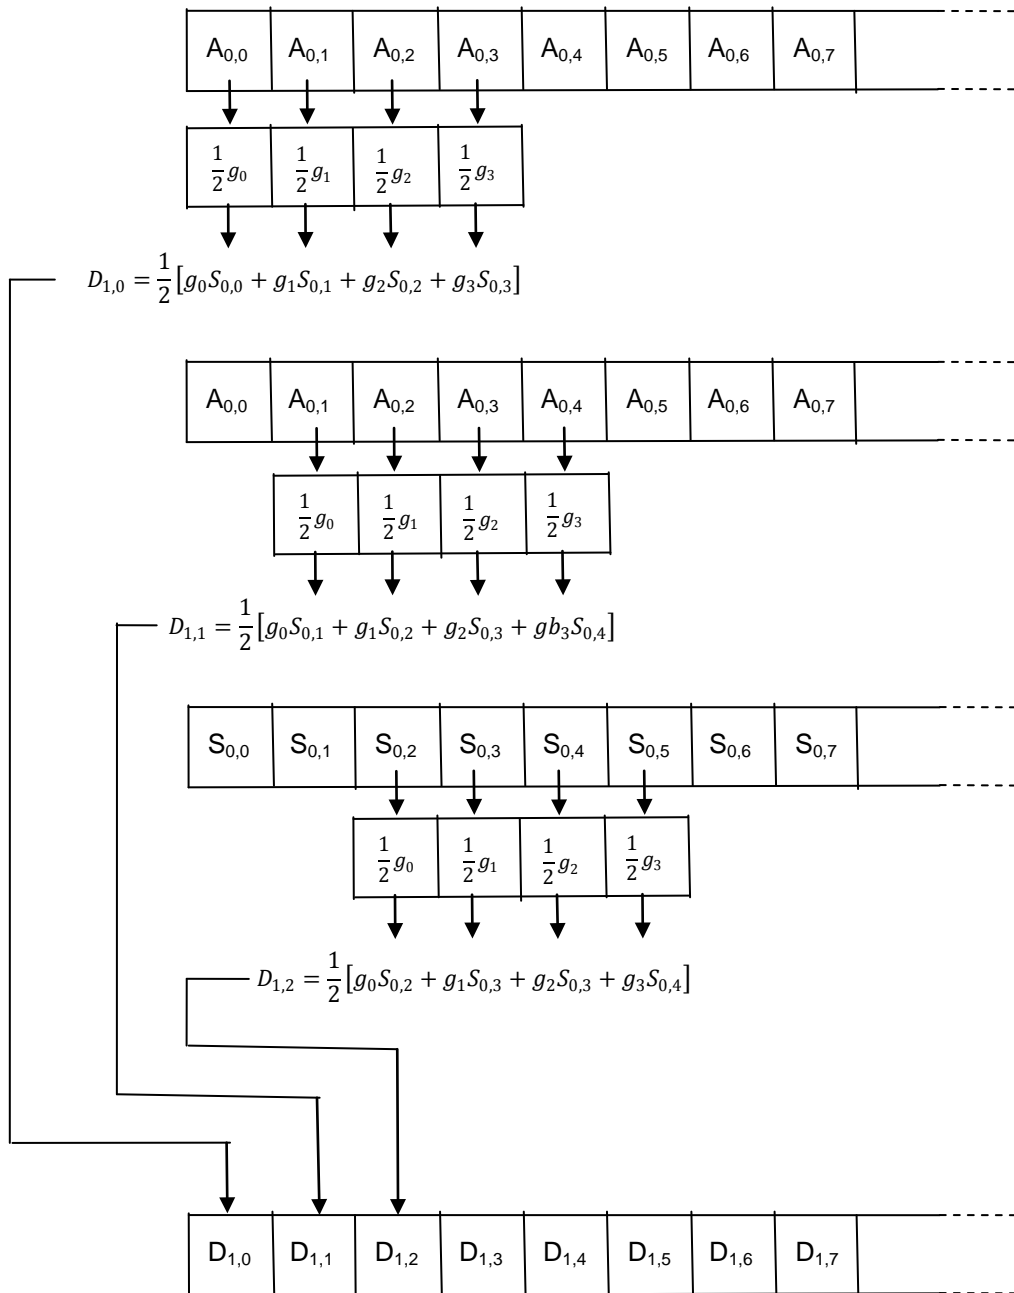


Figura 3.6. Filtrado de descomposición de los detalles con el algoritmo de MODWT.

En la etapa de reconstrucción como en el algoritmo de Mallat también existen los ceros intercalados en las últimas series de aproximación y detalles, la diferencia con del algoritmo de Mallat es que las sumas se dividen entre dos debido a que no existen los submuestreos, ver figura 3.7.

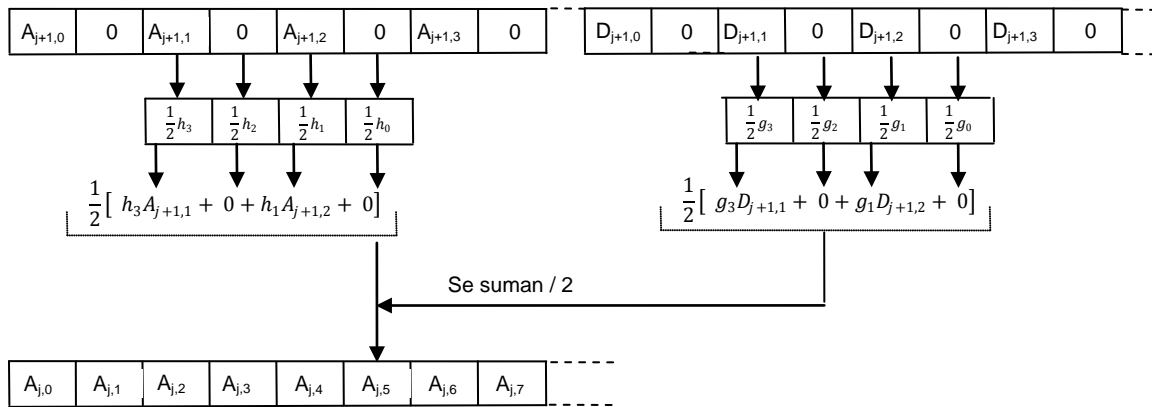


Figura 3.7. Filtrado de la señal en reconstrucción por el algoritmo de MODWT.

iii. La *TW* presenta el problema del fenómeno del efecto de borde producto de la transformada, el inconveniente es que precisamente estos datos del final de la serie son los que se utilizan para realizar el pronóstico. Para explicar este fenómeno se cita el método de la convolución, en ella los coeficientes wavelet utilizados para el filtrado son deslizados a lo largo de la señal, al inicio se emplean los valores que se sitúan adelante de la serie o sea los futuros, al final de éste la señal se acaba pero el proceso aún no ha terminado, entonces para completarlo se requiere obtener una serie de valores. En el esquema de la figura 3.2 cuando el grupo de filtrado inicia en la $A_{0,6}$ los dos últimos elementos de ese grupo no tendrían contraparte para efectuar la multiplicación, entonces el procedimiento indica que se debe de rellenar con algunos valores. Para solucionar este problema existen varios procedimientos. En este trabajo se utilizan cuatro métodos: el primero, Sin Efecto de Borde (SEB) para ello se utilizan los valores futuros, al fin y al cabo se conocen, aunque no es un pronóstico se utiliza para medir el efecto de este fenómeno. Los siguientes tres son los primeros métodos citados en la sección 2.1.1.3. Adicionalmente en el Primer Enfoque modelo *Wavelet-Neuronal-1* (WN1) que se describe más abajo, se utiliza un método que utiliza los valores consecutivos siguientes a la posición 422 en la serie.

3.2.2. Método para el pronóstico

i. El proceso de pronóstico consiste en descomponer la serie original hasta el valor t , se aplica el algoritmo de pronóstico y se obtiene el valor siguiente $t + 1$ pronosticado; la segunda vez, se descompone hasta el valor $t + 1$ de la serie original y se obtiene el siguiente valor $t + 2$ pronosticado; y así sucesivamente hasta llegar al final de la serie original. Es importante recalcar que el pronóstico es a plazo inmediato, ó sea se encuentra el valor siguiente, de acuerdo a la literatura revisada la precipitación es complicada de predecir con este tipo de metodos hibridos wavelet-neuronales a corto, mediano o largo plazo (Nourani et al., 2009; Dastorani et al. 2010; Wang et al., 2011; Wu et al., 2010). Cisneros y Pelczer (2007) hacen un comentario similar pero ellos utilizan un método diferente.

ii. Para encontrar la arquitectura óptima se realiza un mapeo multifuncional con las siguientes configuraciones para *FFBP* y *ANFIS*:

- a) Para el caso del primer enfoque solamente se realizan las descomposiciones con los coeficientes de Haar y Daubechies de orden cuatro (Db4), en el caso del segundo enfoque se utilizan las descomposiciones y reconstrucciones, solamente con los coeficientes de Db4.
- b) Se varía el nivel j del cero al siete.
- c) En el caso de la *FFBP* se define el número de neuronas de la capa oculta de la siguiente manera: 1, 0.5 n , 1.0 n , 1.5 n (Kim y Valdés, 2003), donde n es igual al número de neuronas de la entrada. En el caso de *ANFIS* se varió el número de funciones de membresía de dos a seis, que consistieron en una campana de Gauss.
- d) Se utiliza un entrenamiento cruzado con un algoritmo de terminación temprana (ASCEa, 2000; Cisneros y Pelczer, 2007) para evitar el sobreentrenamiento.
- e) El máximo número de épocas fue de 250.

- f) Los valores de entrada a la red se normalizan de 0.1 a 0.9 para evitar inestabilidad, debido a que se utiliza una función de activación sigmoideal.
- g) Para la validación del proceso se repite el entrenamiento de la red hasta que arrojan un resultado consistente debido a que los pesos se inicializan aleatoriamente.
- h) Se utiliza la función de entrenamiento de Levenberg-Marquardt.
- i) Se varia el número de meses de antelación de uno a seis siendo uno el mes actual.
- j) En el caso de las *ANN* el máximo número de épocas se especifica en 250. En el caso de *ANFIS* se modifica el número de épocas de 1 a 25.
- k) Como medida de desempeño se utiliza la *Root Mean Square Error (RMSE)* el valor objetivo se varia de 1×10^{-1} hasta 1×10^{-9} con intervalos de la unidad en escala logarítmica, además se utiliza el coeficiente de determinación R^2 .

iii. Primer Enfoque: Las descomposiciones se utilizan como insumos al *FFBP* o *ANFIS* según sea el caso, específicamente se introducen los valores de antelación de la señal, su última aproximación y los detalles. Para demostrar la influencia del efecto de borde se utilizaron cinco técnicas de rellenado, la primera consistió en descomponer toda la serie con el propósito de que este fenómeno no influyera en el resultado, esta técnica de rellenado se denomina Sin Efecto de Borde (SEB), pese a ello esto no es una predicción debido a que se está incluyendo la información del periodo de predicción y siempre es necesario tener minucioso cuidado en no incluir información futura (Kim y Valdés, 2003). La repetición de los datos del inicio de la serie fue la segunda técnica de rellenado utilizada y se basa en colocar después del último valor de la serie, el primero, luego el segundo ..., hasta completar el número de datos requeridos por el proceso. En tercer lugar se utilizó una técnica de espejo de los valores, esta se fundamenta en poner después del último valor de la serie el último, penúltimo, antepenúltimo ..., y así sucesivamente hasta lograr la transformada. La cuarta técnica consiste en colocar los valores de la media en

esos valores y la última técnica consistió en ubicar al final de la serie los valores 422, 423, 424, etc. debido a que ese grupo de valores tiene el coeficiente de correlación más alta (0.823) con el grupo de datos de pronóstico. Se realiza un mapeo multifuncional con los incisos del paso ii. En la figura 3.8 se presenta un esquema del primer enfoque.

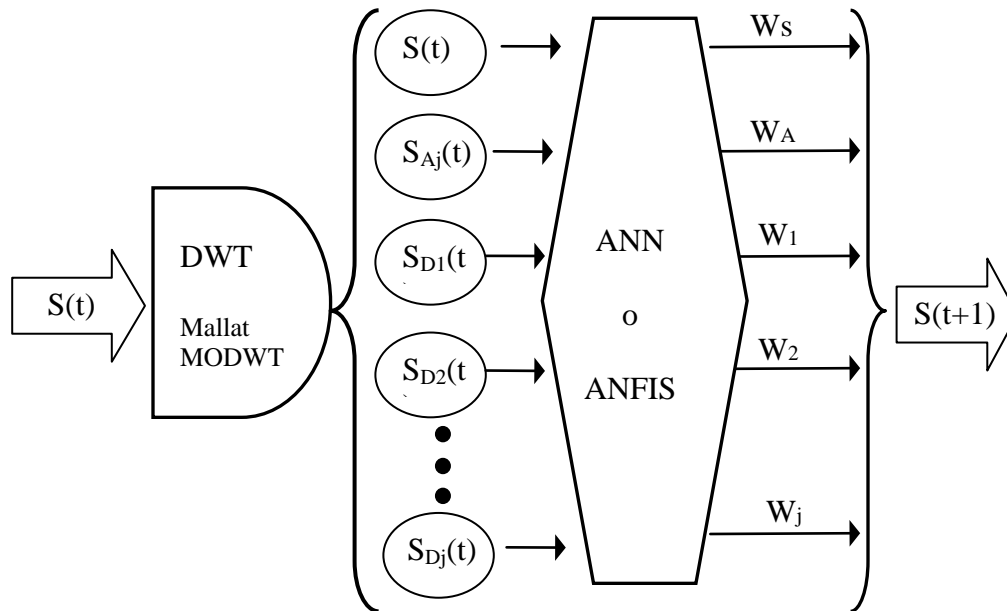


Figura 3.8. Esquema del Primer Enfoque. Se descompone la señal $S(t)$ mediante la DWT , los componentes de detalle $S_{D1}(t)$, $S_{D2}(t)$, ..., $S_{Dj}(t)$; la última aproximación $S_{Aj}(t)$; y la señal original $S(t)$ con diferentes valores de antelación son utilizados como entradas a la ANN o ANFIS, y mediante los pesos W se encuentra el siguiente valor de la serie $S(t+1)$ pronosticado.

iv.- Segundo Enfoque: Consiste en modificar la señal con el propósito de ayudar al algoritmo de predicción a modelar una serie más suave, para ello se realiza una eliminación de las altas frecuencias mediante la DWT , primero se realiza la etapa de descomposición normalmente, después en etapa de reconstrucción radica la diferencia debido a que se eliminan sistemáticamente los detalles del nivel uno hasta el j elegido lo que obtiene una nueva señal más suave. Al eliminar esos detalles se pierde una parte de la señal y aunado a ello se elimina una fracción del efecto de borde y produce uno nuevo. Además esa fracción que

se eliminó produce un ruido que tiene la forma del wavelet madre, este fenómeno es más significativo en relación al número de detalles que se eliminan y a su magnitud. Una vez que se obtiene la nueva señal los algoritmos de predicción trabajan como si fueran autónomos, en esta ocasión se utiliza únicamente el algoritmo de Mallat con los coeficientes Db4 y el rellenado de los valores finales se realiza mediante el método de espejo. Los criterios de desempeño se obtienen de acuerdo a la señal original que es el objeto de nuestra predicción. Como el propósito es identificar cuales coeficientes wavelet de descomposición presentan mayor similitud con la señal original se calcula el coeficiente de correlación para las componentes de los niveles del uno al nueve y se realiza un mapeo multifuncional con los incisos del paso ii. En la figura 3.9 se presenta un esquema del segundo enfoque.

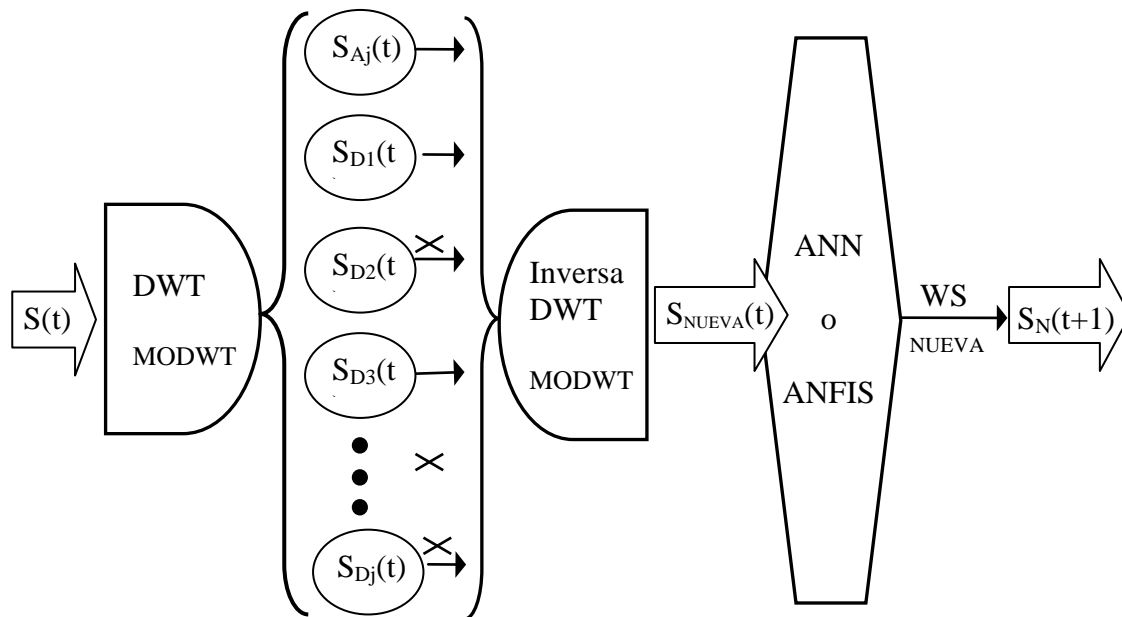


Figura 3.9. Esquema del Segundo Enfoque. Se descompone la señal $S(t)$ mediante la DWT , después se eliminan sistemáticamente los coeficientes de detalle, se reconstruye la señal mediante la DWT inversa, de esta manera se encuentra una señal nueva más suave $S_{NUEVA}(t)$ que es la que se utiliza como entrada con diferentes valores de antelación a los algoritmos de ANN o $ANFIS$, y mediante los pesos WS_{NUEVOS} se encuentra el siguiente valor de la serie nueva $S_N(t+1)$ pronosticado.

v.- Finalmente se analizan de los resultados y se presentan las discusiones y conclusiones.

Capítulo IV
Resultados y Discusiones

4.1. Resultados

En este capítulo se presentan los resultados obtenidos y su comparación con resultados de otros autores. Inicialmente se determina la estación climatológica que se utilizaría en el estudio, para ello se elaboró un inventario de las estaciones climatológicas de la región RH01. En el Apéndice C aparece la información hidroclimatológica que pudo ser recopilada hasta el año 2011, aunque existe más información. La oficial básicamente proviene de tres fuentes: CONAGUA, SEFOA y NOAA, evidentemente la emitida por las estaciones automáticas y el *RADAR* son las que deberían tener una mejor calidad. Sin embargo las estaciones terrestres que opera la CONAGUA y la SEFOA tienen datos faltantes debido a la falla en los sensores o a que simplemente la estación no estaba funcionando en ciertos periodos. Por su parte los datos de la NOAA obtenidos con *RADAR* no tiene información faltante pero el acceso a los archivos es una tarea complicada, se requiere una capacidad instalada de software y hardware a la cual no se tiene acceso. Por otro lado, la información del *RADAR* contiene ruido y hasta el momento no contamos con la capacidad técnica para eliminarlo. No obstante el problema mayor con esta información es que presenta un periodo corto de registro para los fines del método a utilizar. Con base en los criterios de continuidad de los datos, longitud del registro, calidad de la información del total de las estaciones manuales, se eligió la información de la estación climatológica No. 016 Ensenada operada por la CONAGUA, (Figura 4.1). Además, los datos faltantes de esta estación pueden ser completados con los de las estaciones cercanas (Ojos negros, San Carlos, Olivares Mexicanos). La estación se ubica en las coordenadas 31°53'45" latitud norte y 116°35'47" longitud oeste. Se encuentra al noroeste del Estado de Baja California, en la vertiente del océano Pacífico, en la ciudad del mismo nombre. Situada en la cortina de la presa Emilio López Zamora que en lo sucesivo se le nombrará como Ensenada. Los registros de la estación ubicada en la Presa

Abelardo L. Rodríguez situada en Tijuana B.C. es la que contiene el registro más largo pero con información faltante.

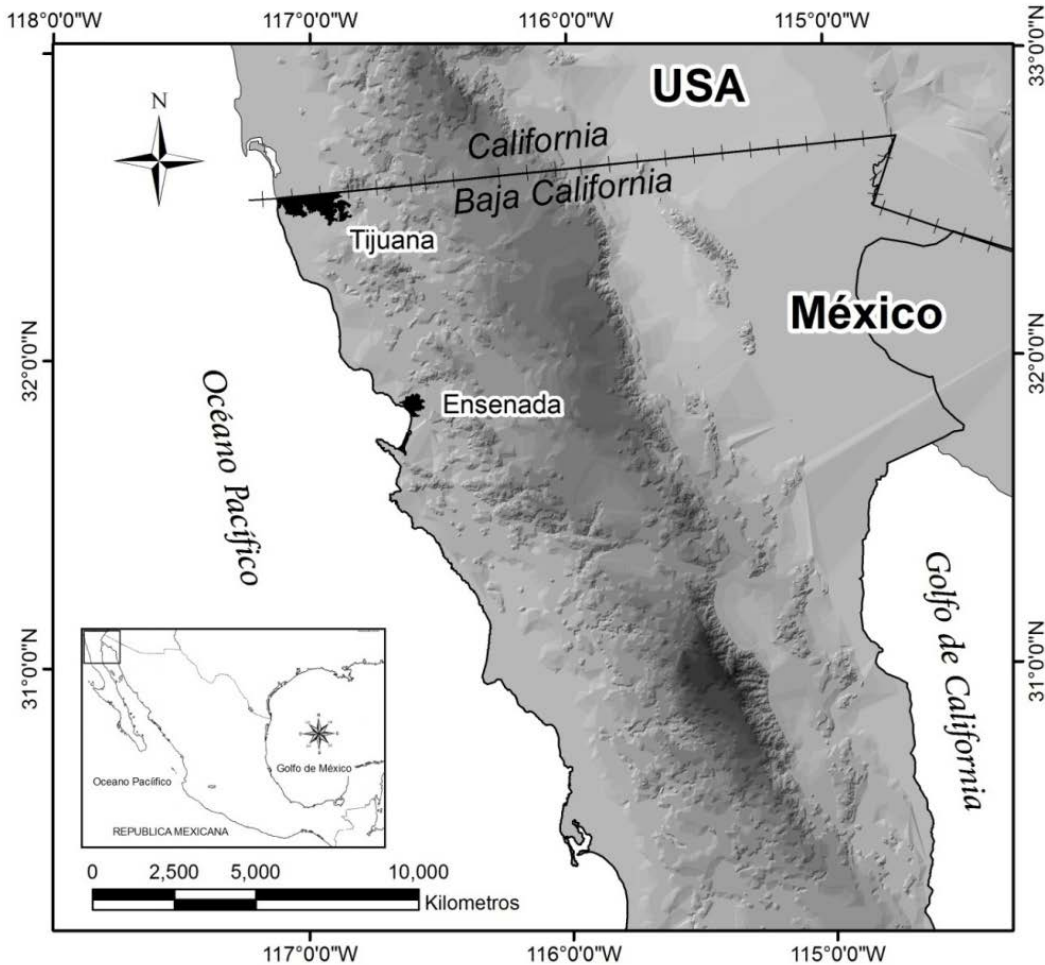


Figura 4.1 Localización de la ciudad de Ensenada donde se ubica la estación 016 con el mismo nombre.

De las estaciones costeras es la que presenta una lámina de precipitación mayor, presenta inclusión de datos con lluvias extremas, además es la que se encuentra más cercana al centro geográfico de la RH01 (Figura 4.2), asimismo en esta figura se observa que las estaciones de la RH01 se encuentran prácticamente sobre las carreteras federales. De ella se escogieron los registros de precipitación de mayo de 1948 a febrero de 2011, a intervalos de medición mensual, lo que corresponde a 754 valores de los cuales se utilizan 622 para entrenamiento, los siguientes 100 para validación y los restantes 32 para pronóstico.

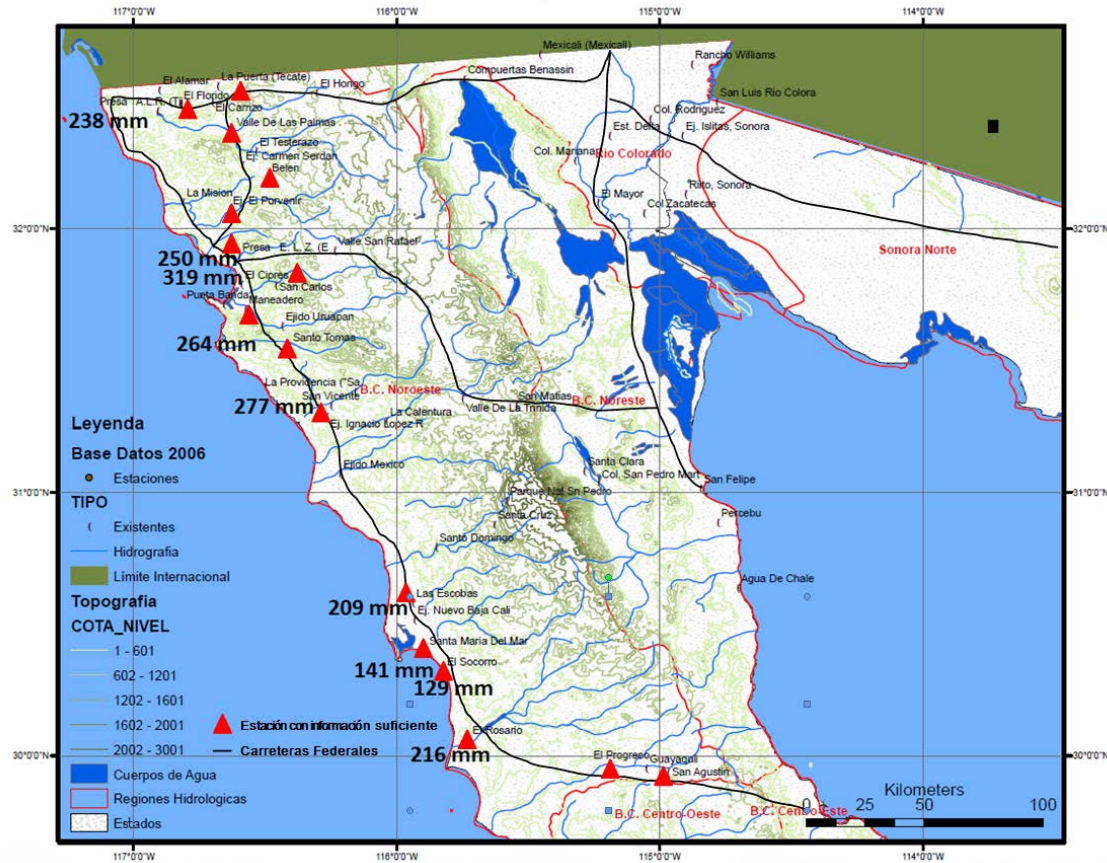


Figura 4.2 Distribución de la precipitación en mm en la zona costa de la RH01 y localización de las estaciones climatológicas con información hidrológicamente suficiente (figura proporcionada por la CONAGUA).

Una vez elegida la estación se realizó el *WMA* con *CWT* empleando el wavelet madre de Morlet, se recuerda que la *CWT* y en este trabajo *WMA* es esencialmente una herramienta de análisis exploratorio de datos que puede ayudar al ojo humano a distinguir características de su interés (Percival y Walden, 2000), y para más detalles del *WMA* refiérase al epígrafe 2.1.1.2.

Se presenta en parte superior de la figura 4.3, la serie de tiempo de precipitación mensual de la estación Ensenada que corresponde a 754 valores, en la parte inferior se despliega el escalograma que es la gráfica de los coeficiente de la transformada $T(a, b)$ de la ecuación 2.9. La distribución de la barra de colores en la figura 4.3 indica la magnitud de los valores de $T(a, b)$, a la izquierda se encuentra la magnitud menor y a la derecha la mayor, o sea entre mayor sea la intensidad de la gama de colores azules menor será el coeficiente y entre mayor

sea la intensidad de la gama de colores rojo mayor será el coeficiente (figura 4.3).

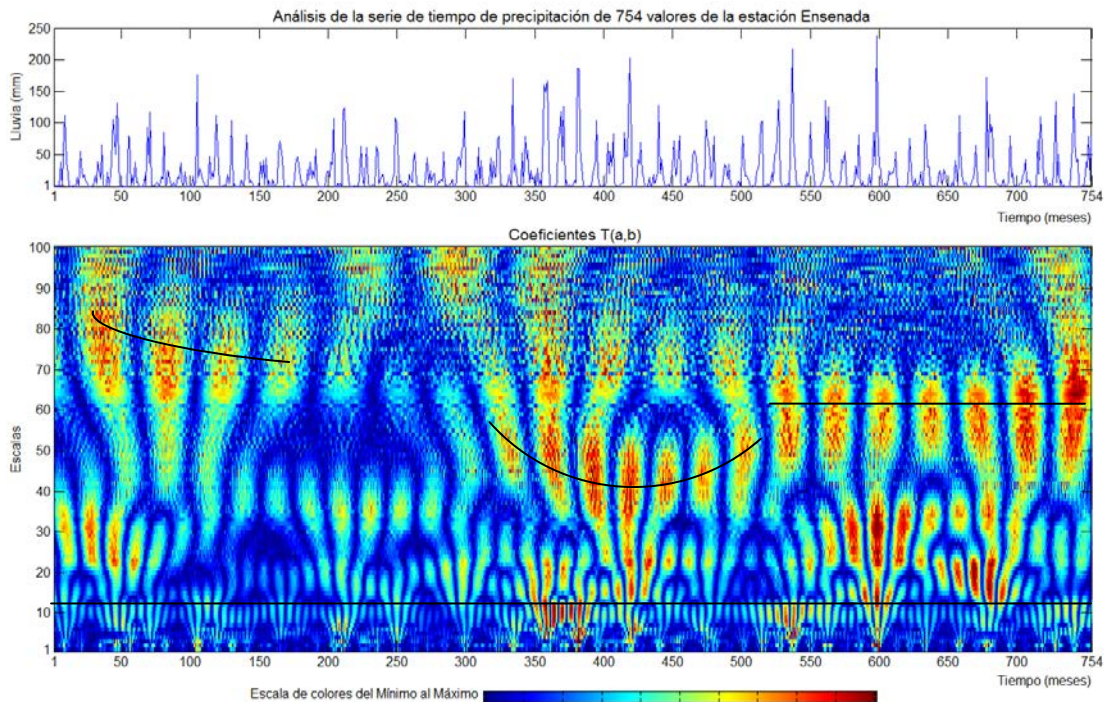


Figura 4.3 Serie de tiempo de datos mensuales de precipitación registrados en la estación climatológica Ensenada (gráfico superior) y escalograma hasta la escala 100 de los 754 meses de precipitación (gráfico inferior). La distribución de la barra de colores indica las magnitudes los valores de $T(a,b)$. Las líneas negras son las estructuras coherentes.

Aclaración [1], Es conveniente mencionar que en el análisis visual del escalograma no interesa conocer con exactitud la magnitud de los coeficientes $T(a,b)$ esto lo resuelve la DWT , lo verdaderamente importante es donde están ubicados aproximadamente los coeficientes mínimos y máximos en escala a (eje y) y posición b (eje x , localización en el tiempo) con el objetivo de encontrar discontinuidades, oscilación de altas frecuencias, ruido y para nuestro caso de estudio identificar estructuras coherentes o similares y su periodicidad. Las estructuras similares o coherentes son grupos de coeficiente $T(a,b)$ que tienen un comportamiento parecido. Se podría pensar que les falta calidad a las imágenes de los escalogramas, en realidad una propiedad de la CWT es que en

las escalas bajas tienen una alta resolución en el tiempo (posición) y una baja resolución en la frecuencia y en las escalas más altas es lo contrario, por eso en el escalograma de la figura 4.3 los rectángulos (ver Figura 2.2) de las escalas más grandes son más anchos y por ende tienen una resolución más tosca, recuerde que el parámetro de escala a modifica la función wavelet (ecuación 2.1). Por otra parte, el significado de la escala a es simplemente el siguiente: $a = 1$ periodo mensual, $a = 2$ periodo bimensual, $a = 3$ periodo trimensual y así sucesivamente; por ejemplo $a = 12$ periodo anual.

En la figura 4.3 la escala máxima de transformación es 100, en general el escalograma muestra que las precipitaciones registradas en la estación Ensenada son irregulares esto debido a que las localizaciones de los coeficientes $T(a, b)$ mínimos y máximos no presentan un arreglo vertical en la posición en las escalas altas, en lo particular se observan los siguientes análisis: Los arreglos formados por las magnitudes de los coeficientes de la escala 12 que corresponde a la periodicidad anual, o sea 12 meses juntos (se marca esa escala en el escalograma con una línea negra constante que abarca toda la serie de tiempo), presenta estructuras coherentes entre los meses 358 y 383, existe otra extra estructura similar de menor magnitud aproximadamente entre los meses 514 y 563, en todo el periodo analizado y en esta escala desde el punto de vista hidrológico se puede considerar que la lluvia es regular, esto se comprueba con lo mencionado en el Capítulo I, epígrafe 1.2. En la escala 12 que evidentemente es baja no presenta estructuras similares en largos periodos y aunque no es lo mismo, se podría decir que es similar a observar la serie de tiempo anual de la estación en estudio. Sin embargo, en niveles superiores se observan tres estructuras coherentes con diferente tendencia y se señalan en el escalograma cada una de ellas con líneas negras: la primera de izquierda a derecha, se observa una arreglo de coeficientes máximos descendente en la escala, aproximadamente en el periodo comprendido entre los meses 30 y 180 entre escalas 65 a 95 (5.5 y 9.7 años respectivamente); la segunda, en la parte central una arreglo de coeficientes máximos en forma curva cóncava hacia arriba, comprendida entre los meses 310 al 530 entre escalas 33 a 57 (2.7 y 4.7

años respectivamente); y la tercera estructura coherente se observa aproximadamente entre los meses 530 y 754 que corresponden a la escala 62 (5.17 años aproximadamente). En la figura 4.4 se presenta una ventana de la tercer estructura de la figura 4.3, de los meses 511 al 754 entre las escalas 38 y 80. Estos rasgos permiten observar al *WMA* con *CWT* con el wavelet madre de Morlet (si se cambia el wavelet madre cambia el escalograma y la convolución se realiza con otra medida de similitud) y en escala promedio 62 desde el punto de vista de la hidrología se puede esperar una lluvia similar aproximadamente cada cinco años, aunque existe coeficientes wavelet de magnitud menor entre los meses 175 y 310, que se puede interpretar como un periodo extraordinariamente seco.

Aclaración [2], para poder observar lo que sucede más a detalle en las escalas más bajas no basta con reducir el tamaño de la ventana, si así se hace el escalograma se vuelve sumamente confuso. Para solucionar este problema se tendría que utilizar una serie de tiempo de precipitación horaria, al implementar la *CWT* y el *WMA* se puede llegar a analizar las escalas diarias, mensuales, anuales, etc. Además se requiere una serie más larga para poder llegar a escalas más altas, por ejemplo siglos.

En la figura 4.4 se observa que los coeficientes más grandes no corresponden a las láminas de precipitación mayores en la serie de tiempo, lo que sucede, como se mencionó arriba en la aclaración [1] la función wavelet conforme se incrementa la escala abarca cada vez mayor longitud de la señal, o sea de una manera simplista conforme sube la escala va promediando los valores de la precipitación.

En la Figura 4.5 se presenta el escalograma hasta la escala de transformación de 256, en esta ocasión se analizan conjuntamente alrededor de las escalas 30, 60, 120, 180 y 240, estas escalas están marcadas en el escalograma con líneas negras horizontales, y corresponden a los periodos de 2.5, 5, 10, 15 y 20 años respectivamente.

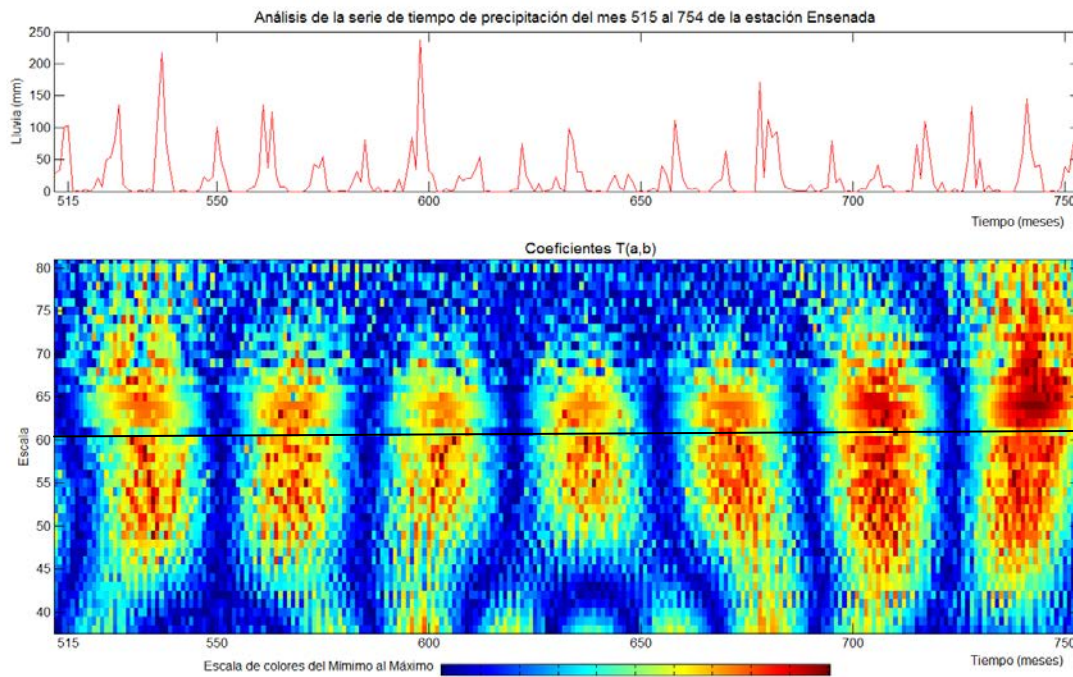


Figura 4.4 Escalograma correspondiente a una ventana de la figura 4.3, entre las escalas 38 y 80 de los meses 511 al 754 y serie de tiempo de precipitación correspondiente al mismo periodo para la estación climatológica Ensenada.

En relación a periodicidad cercana a 2.5 años en el periodo evaluado los coeficientes no tienen una regularidad, además se puede decir que no existe una estructura coherente. Ahora se comentan las restantes periodicidades alrededor de 5, 10, 15 y 20 años que son las réplicas de la periodicidad de cada cinco años. Como se mencionó anteriormente esta lluvia de periodicidad aproximadamente quinquenal tiene variaciones, es regular más o menos en la escala de 10 años, pero en la escala correspondiente a los 15 años presenta un periodo con coeficientes mínimos entre los meses 80 y 220, asimismo en el periodo comprendido entre los meses 520 y 680 lo que la vuelve irregular. En la periodicidad correspondiente a la escala de 20 años se vuelve nuevamente regular.

Este análisis del escalograma nos indica que la serie de tiempo que se pretende pronosticar es no determinista debido a que tiene cierto grado de aleatoriedad y es un fenómeno climatológico no-estacionario porque sus propiedades varían

con el tiempo. Para determinar el grado de aleatoriedad se calculan parámetros estadísticos e indicadores de la teoría del caos.

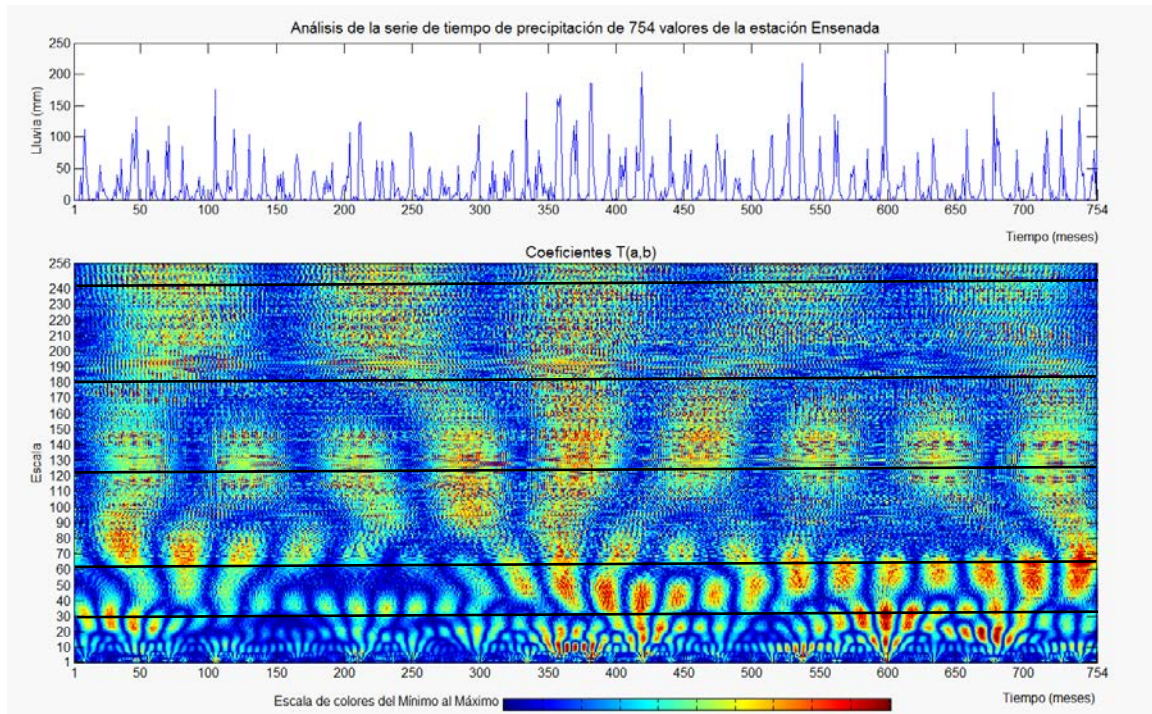


Figura 4.5 Escalograma de la estación Ensenada, para lluvias mensuales de 1948 a 2004, o sea 754 valores. Se presenta una lluvia característica en la escala nueve aproximadamente entre los años 350 y 390.

En la tabla 4.1 se presentan los valores estadísticos y los indicadores caóticos de las series de tiempo de la estación Ensenada (figura 4.6), los renglones indican cuatro grupos de valores: entrenamiento, validación, pronóstico para todos los datos (754) de la serie de tiempo elegida. De la segunda a la onceava columna se exhiben para cada grupo de datos: número total de datos, la media, el valor máximo, la desviación estándar, sesgo, coeficiente de autocorrelación 1, 3, 12 y 24 meses, el exponente de Hurst y el exponente de Lyapunov.

En esa misma tabla 4.1 el valor mayor del máximo de precipitación mensual corresponde a los datos de entrenamiento de la estación Ensenada (237.6 mm) mientras que el valor menor corresponde a los datos de pronóstico (145.5 mm). En este caso, el algoritmo de pronóstico debe validar y predecir siempre valores con medias y valores máximos inferiores a los datos de entrenamiento. Todas

las distribuciones están sesgadas hacia la derecha, aunque los más sesgados son los de entrenamiento.

Tabla 4.1 Información relativa a los datos de precipitación de la estación Ensenada

Estación	N	\bar{x}_{media} (mm)	x_{max} (mm)	S_x (mm)	c_{sx}	r_1	r_3	r_{12}	r_{24}	H	λ
Ensenada											
Entrenamiento	622	21.47	237.6	35.20	2.52	0.398	-0.017	0.271	0.351	0.617	0.492
Validación	100	18.64	171.3	32.03	2.41	0.301	0.080	0.061	0.131	0.522	0.867
Pronóstico	32	27.09	145.5	39.15	1.63	0.265	-0.164	0.187	0.192	0.532	0.261
Total de datos	754	21.71	237.6	35.37	2.47	0.393	-0.024	0.272	0.276	0.593	0.513

En la tabla 4.1 el coeficiente de autocorrelación con valor r_1 es el más significativo en relación a las más cercanas al final de la serie y existe una similitud con los valores anuales r_{12} y r_{24} , valores próximos a cero indican autocorrelación casi nula. Los indicadores caóticos muestran que la serie tiene una alta componente de altas frecuencias y ruido. Los exponentes de Hurst (penúltima columna, tabla 4.1) adquieren valores entre 0.522 y 0.617, los cercanos a 0.5 indican que las series son prácticamente aleatorias, como en este caso, los cercanos a 1.0 manifiestan que las series son determinísticas y estacionarias. Los exponentes de Lyapunov positivos indican que las series son caóticas y no se pueden predecir, como los obtenidos para esta serie (tabla 4.1), exponentes de Lyapunov con valor negativos sugieren que las series son predecibles.

La descomposición de la serie de precipitación mensual para Ensenada por el método de *MODWT*, aproximación nivel tres y los detalles del nivel uno hasta el tres para la función wavelet de Db4 se presentan en la figura 4.7. En esta figura se observa que la longitud de las descomposiciones son iguales a la de la serie original, esto tiene una ventaja debido a que se puede trabajar con cualquier serie de tiempo a diferencia del algoritmo de Mallat que la longitud de la serie debe tener una longitud igual a 2^j (ver epígrafe 2.2.1.2), en el caso que esta característica no se cumpla se rellena de ceros el inicio de la serie con el propósito de realizar el filtrado y estos valores se omiten en la etapa de pronóstico. La ventaja del algoritmo de Mallat es el suavizado ya que cada vez que se incrementa el índice de escala se va ampliando el periodo y mientras que

en el algoritmo de *MODWT* la periodicidad se mantiene constante. Otra diferencia entre los dos algoritmos es la penetración del efecto de borde en el proceso de filtrado (ver apartado 2.1.1.3).

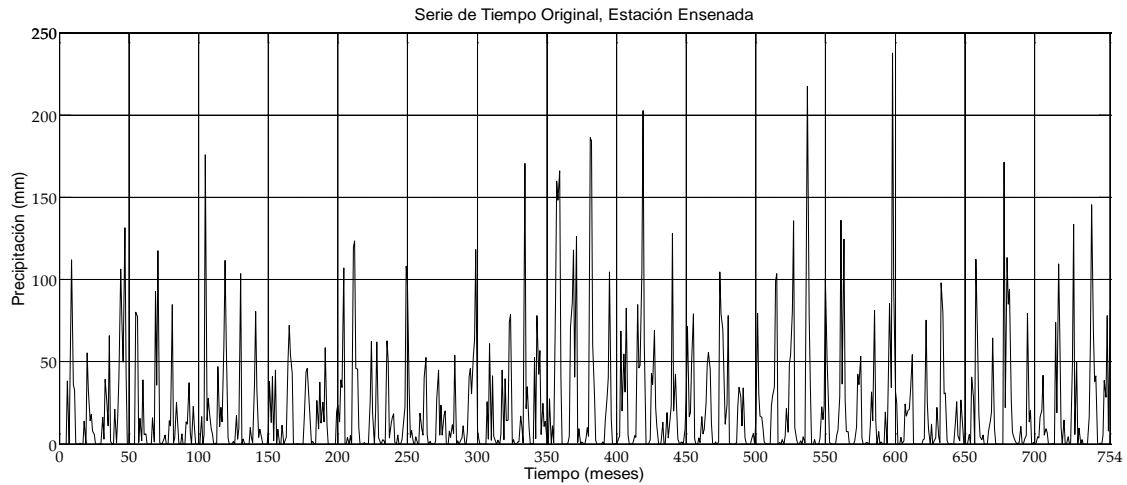


Figura 4.6 Serie de tiempo de precipitación mensual de la estación Ensenada de Mayo de 1948 a Febrero de 2011.

Se presentan de forma resumida en la tabla 4.2 los mejores resultados del método WN del primer enfoque, que corresponde al mapeo realizado con todas las configuraciones propuestas en el capítulo III. Solamente se anotan los más simples debido a que existen resultados similares con otros arreglos (ver epígrafe 2.2.2.3). En la tabla 4.2 los renglones representan los métodos de pronóstico, los primeros tres son métodos autónomos: *FFBP*, *ANFIS*, Media y le continúan los cuatro híbridos: *Mallat-FFBP*, *Mallat-ANFIS*, *MODWT-FFBP* y *MODWT-ANFIS*. Los modelos híbridos tienen diferentes configuraciones para modificar el efecto de borde, éstas se explican claramente en el capítulo III. En la misma tabla 4.2 las columnas se refieren a (de la segunda a la séptima) función wavelet empleada, nivel de descomposición j , RMSE para el mejor entrenamiento encontrados, arquitectura, error objetivo en el entrenamiento de la red (aunque se utiliza un algoritmo de correlación cruzada o también conocido como de terminación temprana, ver epígrafe 2.2.2.4), número de épocas alcanzadas, de la octava a la treceava columna se muestran los indicadores de

desempeño $RMSE$ y R^2 para los tres grupos de datos: entrenamiento validación y pronóstico.




Figura 4.7 Descomposiciones de la serie de Ensenada con el algoritmo de MODWT hasta el nivel 3.

En relación a la cuarta columna (mejor entrenamiento) de la tabla 4.2, que se utiliza para ver el comportamiento del método de correlación cruzada, se observa que el indicador de desempeño $RMSE$ disminuye empleando los métodos híbridos en relación con los métodos autónomos, esto podría indicar que la DWT ayuda a los métodos de pronóstico $FFBP$ y $ANFIS$ a modelar la serie de tiempo en el entrenamiento debido a que mejora su desempeño, sin embargo no es así, en un instante t los coeficientes producto de las descomposiciones estrictamente hablando guardan información futura debido al proceso de filtrado para llevar a cabo la convolución. En esta misma columna, la mayoría de los casos presentan valores de entrenamiento menores que los reportados en la octava columna (entrenamiento en términos del $RMSE$), esto se debe a que los mejores pronósticos (penúltima columna) se logran con un entrenamiento más holgado ya que el algoritmo de pronóstico requiere de generalización (ver epígrafe 2.2.2.4).

Tabla 4.2 Resultados del modelo WN del primer enfoque.

Método en el borde	Función Wavelet	j	Mejor Entrenamiento RMSE (mm)	Arquitectura	Error Objetivo 10^x	Épocas	Entrenamiento		Validación		Pronóstico	
							RMSE (mm)	R^2	RMSE (mm)	R^2	RMSE (mm)	R^2
FFBP			29.73	5-2-1	-4	45	30.12	0.30	28.12	0.24	33.37	0.26
ANFIS			24.29	2-7-2-1	-4	8	30.35	0.28	33.92	0.39	19.33	0.40
Media							35.66	0.00	32.02	0.00	38.91	0.00
Mallat-FFBP												
SEB	Db4	2	5.47	24-4-1	-4	31	5.52	0.98	65.42	0.08	6.39	0.97
Repetir	Haar	1	14.87	9-8-1	-4	26	24.85	0.57	61.96	0.08	31.13	0.43
Espejo	Haar	1	12.60	18-9-1	-4	56	23.67	0.57	64.32	0.12	31.37	0.35
Media	Haar	1	12.60	18-9-1	-4	44	23.67	0.57	64.32	0.12	31.34	0.35
Mallat-ANFIS												
SEB	Db4	1	12.64	3-2-3-3-1	-2	10	17.91	0.75	63.66	0.11	24.04	0.64
Repetir	Haar	1	23.58	3-2-3-4-1	-2	10	26.19	0.46	57.27	0.07	35.76	0.16
Espejo	Db4	1	19.70	3-4-2-2-1	-2	10	22.44	0.60	63.42	0.10	34.21	0.24
Media	Haar	1	19.70	3-5-2-2-1	-1	10	22.43	0.60	63.98	0.07	35.54	0.18
MODWT- FFBP												
SEB	Db4	3	0.01	25-12-1	-4	42	1.18	1.00	0.00	1.00	0.00	1.00
Repetir	Db4	5	0.01	7-4-1	-4	53	15.21	0.82	15.76	0.76	39.30	0.08
Espejo	Db4	5	0.01	28-2-1	-4	39	1.11	1.00	00.12	1.00	40.93	0.08
Media	Db4	4	0.01	6-17-1	-4	47	10.67	0.91	10.05	0.90	34.47	0.26
422	Db4	4	0.01	6-15-1	-4	62	10.36	0.92	9.52	0.91	23.68	0.67
MODWT- ANFIS												
SEB	Db4	1	0.00	3-2-2-2-1	-1	10	0.00	1.00	0.00	1.00	0.00	1.00
Repetir	Db4	1	0.01	3-5-5-4-1	-1	10	0.02	1.00	0.04	1.00	45.24	0.01
Espejo	Haar	1	0.00	3-4-5-5-1	-1	10	0.02	1.00	2.20	1.00	40.72	0.13
Media	Db4	1	0.00	3-3-3-3-1	-1	10	0.02	1.00	0.33	1.00	38.87	0.05
422	Db4	1	0.01	3-3-5-5-1	-1	10	0.02	1.00	0.03	1.00	23.68	0.68

En la tabla 4.2 se muestran los métodos autónomos en los tres primeros renglones (*FFBP*, *ANFIS* y *Media*) en términos de los indicadores de desempeño *RMSE* y R^2 el mejor método es el *ANFIS* con valores de 19.33 mm y 0.40 respectivamente, bajo estos mismos indicadores la *FFBP* es ligeramente superior que la *Media* que consiste en calcular la media de los valores. El desempeño de estos dos últimos métodos se puede apreciar gráficamente en la figura 4.8 y 4.9.

En la misma tabla 4.2 se muestran los métodos híbridos en los cuatro bloques de datos de la parte inferior, haciendo a un lado las configuraciones SEB y 422, cuando el modelo WN emplea *MODWT* es más hábil para modelar la serie en las etapas de entrenamiento y validación, esto se observa en los indicadores de desempeño *RMSE* para estas dos etapas, debido a que la penetración del efecto de borde es mayor en algoritmo *MODWT* que en el Mallat (ver apartado 2.1.1.3). Para estos mismos grupos en la etapa de pronóstico el algoritmo de Mallat presenta mejores resultados en comparación del *MODWT* en




Figura 4.8 Resultados de entrenamiento, validación y pronóstico utilizando el segundo enfoque con el algoritmo Mallat-FFBP.




Figura 4.9. Resultados con el método ANFIS autónomo.

términos del mismo indicador de desempeño, por la misma razón de la penetración de efecto de borde.

De hecho, el algoritmo de Mallat con la función wavelet de Haar no presenta efecto de borde debido a que solamente tiene dos coeficientes de escalamiento y wavelet (ver apartado 2.1.1.3). Debido a esta particularidad, la función wavelet de Haar aunque es demasiado simple para representar la señal al conjuntarla con el algoritmo Mallat-*FFBP* es la que mejores indicadores de desempeño presenta al comparar los métodos híbridos, como se puede ver en la columna de pronóstico. Además los métodos híbridos que emplean *MODWT* (últimos dos bloques de valores) tienen una inconsistencia en los indicadores de desempeño, son casi perfectos en las columnas de entrenamiento y validación pero en etapa de pronóstico se desploman esos indicadores, debido al efecto de borde.

De la misma tabla 4.2 la configuración SEB en términos de los indicadores de desempeño, en todos los casos, es el mejor rendimiento en la columna de pronóstico, lo que es una muestra clara de la influencia del efecto de borde. En etapa de entrenamiento y validación, los valores de RMSE tienen un comportamiento similar a la configuración de espejo. En la misma tabla 4.2 otra prueba contundente de la influencia del efecto de borde está en relación a la configuración 422, que fue elaborada a propósito para los modelos híbridos *MODWT-FFBP* y *MODWT-ANFIS*, en esta configuración 422 se muestra la mejoría en la etapa de pronóstico (últimas dos columnas) de los indicadores de desempeño, esto se debe a que los datos fueron elegidos quirúrgicamente a partir del tiempo $t = 422$ para realizar el filtrado en el proceso de convolución. Estos valores son los que tienen un coeficiente de correlación mayor con el grupo de datos de pronóstico, es decir son lo que más se parecen a los valores que se pretende pronosticar. Es decir con el método WN primer enfoque el algoritmo de pronóstico tiene una amplia dependencia con los valores que se utilizan para realizar el rellenado en el filtrado, por ejemplo si la serie es determinista y estacionaria, se tiene una mayor posibilidad de que los datos en el rellenado se parezcan.

En la tabla 4.2 en la columna de pronóstico de los métodos que no tienen influencia en el efecto de borde que son: todos los autónomos y los que utilizan la función wavelet de Haar con la descomposición de Mallat, o sea Mallat-*FFBP* y Mallat-*ANFIS*, de todos los resultados el que mejores indicadores de desempeño presenta en la columna de pronóstico es el *ANFIS*.

En relación al segundo enfoque la tabla 4.3 muestra los resultados del cálculo de los coeficientes de correlación. La tabla 4.3 tiene dos renglones, el primero son las aproximaciones y el segundo los detalles. Las columnas dos a la diez contienen los coeficientes de correlación para nueve niveles de descomposición. En esa misma tabla, los coeficientes de correlación para las aproximaciones tienen una correlación más elevada que los de detalle, la mayor se encuentra en el nivel uno (0.826) y van decreciendo conforme se incrementa el nivel, esto indica que si el algoritmo de pronóstico puede modelar en los primeros niveles perderá menos información en el suavizado pero algunas componentes de ruido y altas frecuencias se mantendrán en el suavizado. Lo ideal sería que la correlación mayor existiera en un nivel más bajo (índice de nivel mayor) para que la nueva señal pudiera contener mayor cantidad de bajas frecuencias y las componentes de altas frecuencia y ruido sean mínimas.

Tabla 4.3 Coeficiente de correlación de la señal con las descomposiciones del nivel 1 a 9.

	Nivel j								
	1	2	3	4	5	6	7	8	9
Algoritmo de Mallat Db4									
Aproximaciones	0.826	0.631	0.430	0.379	0.322	0.305	0.285	0.296	0.230
Detalles	-0.021	0.010	-0.217	-0.058	0.036	0.023	-0.058	-0.192	-0.230

Por ejemplo, en el caso de niveles mensuales de lagos en Turquía, Kişi (2009) calculó el coeficiente de correlación de la componente de aproximación del nivel cinco (periodicidad aproximada de 2.5 años) igual a (0.890) los coeficientes de correlación de los coeficientes de detalle descienden del nivel cinco al nivel uno de 0.190 a -0.006, esto le permite al autor modelar por separado cada componente y mejorar su indicador de desempeño. Por su parte Partal (2009) trabajó con series de tiempo diarias de temperatura, radiación solar, velocidad del viento, humedad relativa para predecir la evapotranspiración de referencia en San Diego California, EUA y encontró un coeficiente de correlación cercano a

uno entre la mayoría de las variables asociadas con la evapotranspiración de referencia significativo en las aproximaciones y detalles del nivel 10 (periodicidad aproximada trianual), permitiéndole al autor realizar un tratamiento similar al mencionado anteriormente. Para estos dos casos la señal se puede reconstruir eliminando casi por completo la componente de altas frecuencias y ruido. En la serie de la estación Ensenada como el nivel de descomposición es uno la nueva señal mantendrá una componente significativa de altas frecuencias y ruido, por lo que seguirá siendo no determinista y no estacionaria.

En la Tabla 4.4 se presentan de manera condensada los mejores resultados del modelo WN del segundo enfoque que solamente utiliza el algoritmo de Mallat, que corresponde al mapeo realizado con todas las configuraciones propuestas en el capítulo de metodología. Solamente se anotan los más simples debido a que existen resultados similares con otros arreglos (ver epígrafe 2.2.2.3). En esa tabla la primera columna representa los métodos de pronóstico *FFBP* y *ANFIS*, la segunda la función wavelet utilizada, la tercera el máximo nivel de descomposición (aproximación A) y la cuarta el rango de niveles de los detalles que fueron utilizados para la reconstrucción (detalle D). Las siguientes columnas (5-14) son similares a las que se presentan (4-13) en tabla 4.2. En esa tabla el comportamiento del método de correlación cruzada tiene el mismo comportamiento que en primer enfoque.

Tabla 4.4 Resultados del modelo WN del segundo enfoque.

Método de pronóstico	Función Wavelet	A <i>j</i>	D <i>j</i>	Mejor Entrenamiento RMSE (mm)	Arquitectura	Error Objetivo 10^x	Épocas	Entrenamiento		Validación		Pronóstico	
								RMSE (mm)	R^2	RMSE (mm)	R^2	RMSE (mm)	R^2
Suavizado con Mallat													
FFBP	Db4	6	5-6	24.22	10-1-1	-2	13	35.66	0.02	49.58	0.00	39.32	0.18
ANFIS	Db4	6	3-6	22.71	2-4-5-1	-3	14	35.00	0.04	50.72	0.02	34.58	0.42

De los dos métodos empleados el que mejores indicadores de desempeño presenta en la columna de pronóstico es el Mallat-*ANFIS* utilizando para la reconstrucción de la señal la aproximación del nivel seis, además los detalles de los niveles cinco y seis. En esta tabla se observa que utilizar Mallat-*FFBP* para

predecir la serie de tiempo en esta región prácticamente es similar a emplear la media de la señal cuyos resultados aparecen en la tabla 4.2, y se esquematiza en la figura 4.8. De los dos enfoques estudiados *ANFIS* autónomo (tabla 4.2) supera el desempeño del Algoritmo Mallat-*ANFIS* en términos de los indicadores de desempeño para la columna de pronóstico mostrado en la tabla 4.4.

La figura 4.8 señal la aproximación del nivel seis, reconstruida con los detalles de los niveles cinco y seis, muestra los resultados para los valores agrupados de entrenamiento, validación y pronóstico utilizando el segundo enfoque con Mallat-*FFBP*. Se observa la serie de tiempo de la estación Ensenada con 754 valores, similar a la figura 4.6, la línea discontinua horizontal es la media de la señal y los puntos oscuros que forman una línea discreta en forma de olas son los valores calculados por el modelo para los tres agrupamientos. Precisamente esas olas son el ruido wavelet que tiene la forma de la función wavelet de Daubechies (ver figura 2.1a).

En la figura 4.8, la nueva señal es constituida por los coeficientes de aproximación del nivel seis, además los coeficientes de detalle de los niveles cinco y seis, cuyos coeficientes de correlación son (0.305, 0.036 y 0.023) respectivamente en relación con la señal original. La señal original es constituida en general por altas frecuencias y ruido, y por esa razón se requiere descomponerla a un nivel seis que corresponde a un periodo de 5.3 años aproximadamente, debido a que el algoritmo de Mallat tiene una escala diádica, esto fortalece la evidencia encontrada en el *WMA* en el análisis de los escalogramas (ver interpretaciones de las figuras 4.3, 4.4 y 4.5) y no en el nivel uno como lo indica el coeficiente de correlación (0.826) de la tabla 4.3. Por eso en una serie no-determinista y no estacionaria como la que se analiza en este trabajo el nivel de descomposición j no depende del coeficiente de correlación, lo que refuerza la importancia de calcular los exponentes de Hurst y Lyapunov como indicadores caóticos de la serie para determinar el grado de predictibilidad de la serie de tiempo. En la literatura revisada ninguna de las investigaciones utiliza estos exponentes. En la misma figura 4.8 se observa en el intervalo de pronóstico la distorsión producto del fenómeno del efecto de borde.

De todos los métodos empleados no dependientes del método empleado para el relleno para realizar el filtrado, los mejores indicadores de desempeño en la columna de pronóstico son los que obtiene el *ANFIS* autónomo. En la figura 4.9 se muestran los valores calculados, el mejor modelo (*ANFIS* autónomo) y la serie original, observándose que los valores extremos en el periodo de lluvia máxima son subestimados y en sequía son sobreestimados, aunque en ocasiones se obtienen valores negativos, lo que indica que el *ANFIS* no puede interpretar los valores extremos.

4.2. Discusiones

En los algoritmos de pronóstico un parámetro importante es el número de variables de entrada, ya sea utilizando valores de antelación o variables asociadas al modelo. Utilizar un solo dato de entrada al modelo es una tarea en vano, debido a que los algoritmos de pronóstico no cuentan con una base estable de decisión. Jang (1993) establece una arquitectura mínima de *ANFIS* con dos variables de entrada, para el caso de las *ANN* y *FFBP* la arquitectura es más flexible, sin embargo en nuestras pruebas de variables sintéticas y de precipitación pluvial el algoritmo pierde la base de decisión. Esta técnica la ha utilizado: en el caso de las *ANN*, Tiwari y Chettergee (2010) y Kim y Valdés (2003), en el caso de *ANFIS*, Partal y Kişi (2007); por lo que difiero de los resultados obtenidos en las investigaciones que utilizan arquitecturas con una sola variable de entrada y con ella encuentran su mejor indicador de desempeño. Al inicio de esta investigación se realizaron pruebas sintéticas con los algoritmos de pronóstico, la serie que se utilizó es determinista y estacionaria es ampliamente conocida, se denomina función seno. Si el algoritmo de pronóstico no puede predecir una función seno una serie más aleatoria y caótica no la va a poder representar. La prueba consistió en obtener una serie de la función seno de 1024 puntos, y cada punto esta espaciado 10 grados obteniéndose tres grupos de valores: entrenamiento, validación y pronóstico que equivalen a un periodo. Se utilizaron los algoritmos de pronóstico *ANN* y *ANFIS* con diferentes valores de antelación.

Las figuras 4.10 4.11 y 4.12 presentan la pruebas sintéticas realizadas con el algoritmo ANN, en ellas se muestra la serie del seno con una línea continua azul, los valores de entrenamiento con círculos azules, los valores de validación son triángulos rojos y los valores de pronóstico están simbolizados con diamantes negros, y al final de la serie (punto 1025) se grafica el pronóstico real. La figura 4.10 muestra el desempeño de la ANN modelando la función seno, con tres valores de antelación, al inicio faltan tres valores estimados debido a que son los que se utilizan para encontrar el primer valor de entrenamiento, al final de la serie se observa el pronóstico verdadero. La figura 4.11 muestra el desempeño de la ANN modelando la función seno, con dos valores de antelación, al inicio faltan dos valores estimados debido a que son los que se utilizan para encontrar el primer valor de entrenamiento, al final de la serie se observa el pronóstico verdadero. En las figuras 4.10 y 4.11 a simple vista se ve que el modelado de la función seno es adecuado.

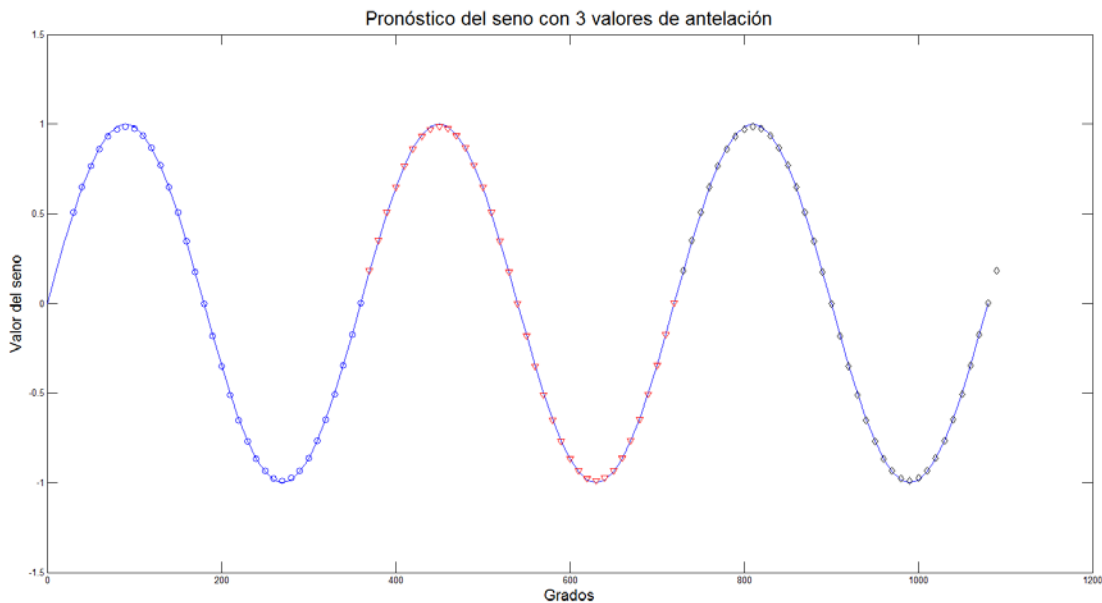


Figura 4.10. Resultados del pronóstico de la función seno con tres valores de antelación empleando ANN para tres grupos de datos: entrenamiento, validación y pronóstico.

En la figura 4.12 se muestra el desempeño de la ANN modelando la función seno, con un valor de antelación, y a simple vista se observa que la ANN copia los valores previos. Esto es debido a que se desestabiliza y no sabe qué dirección tomar y simplemente al valor pronosticado le asigna el valor anterior,

de hecho en la versión de Matlab 7.1 le asigna el valor de la media, en las versiones 2010 y 2011 copia el valor anterior. Esto se observa claramente en la prueba sintética, pero con una señal no determinista y no estacionaria con componentes de altas frecuencias y ruido es sumamente difícil darse cuenta. Un fenómeno similar ocurre con ANFIS lo que se muestra en las Figuras 4.13 y 4.14 para valores de antelación 2 y 1 respectivamente.

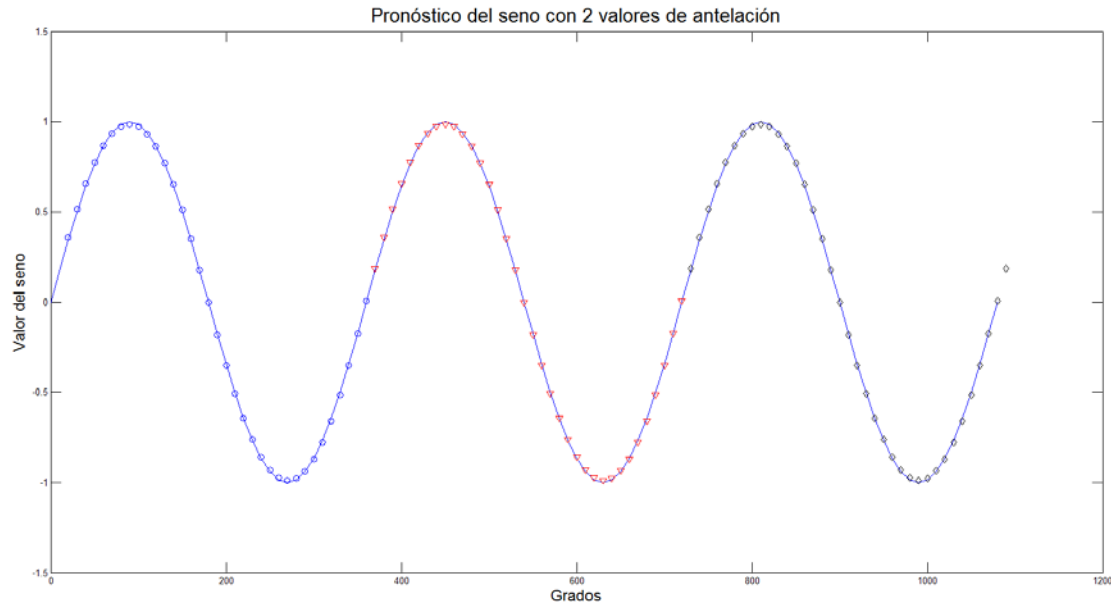


Figura 4.11. Resultados del pronóstico de la función seno con dos valores de antelación empleando ANN para tres grupos de datos: entrenamiento, validación y pronóstico.

Por otra parte, Kim y Valdés (2003) y Adamowsky (2008) son los autores que mencionan el método que utilizan para solucionar el efecto de borde, el resto de los autores ni lo nombran, siendo un fenómeno sumamente importante que influye directamente en el pronóstico.

Los tres enfoques de los modelos híbridos wavelet neuronal o wavelet neurodifusos mencionados en el capítulo II se sintetizan de la siguiente manera: el primero, se basa en descomponer la señal con *DWT* y utilizar las descomposiciones como insumos a las *ANN* o alguna de sus variaciones; el segundo enfoque, consiste en suavizar la señal y una vez encontrada una nueva señal se predice su comportamiento; el tercero, es de Descomposición-Pronóstico-Reconstrucción, se descomponen las series en subseñales con la

DWT, cada una de ellas se predice utilizando alguna herramienta para este fin y por último a partir de las subseries pronosticadas se reconstruye la serie original, utilizando la transformación inversa o ANN.




Figura 4.12. Resultados del pronóstico de la función seno con un valor de antelación empleando ANN para tres grupos de datos: entrenamiento, validación y pronóstico.

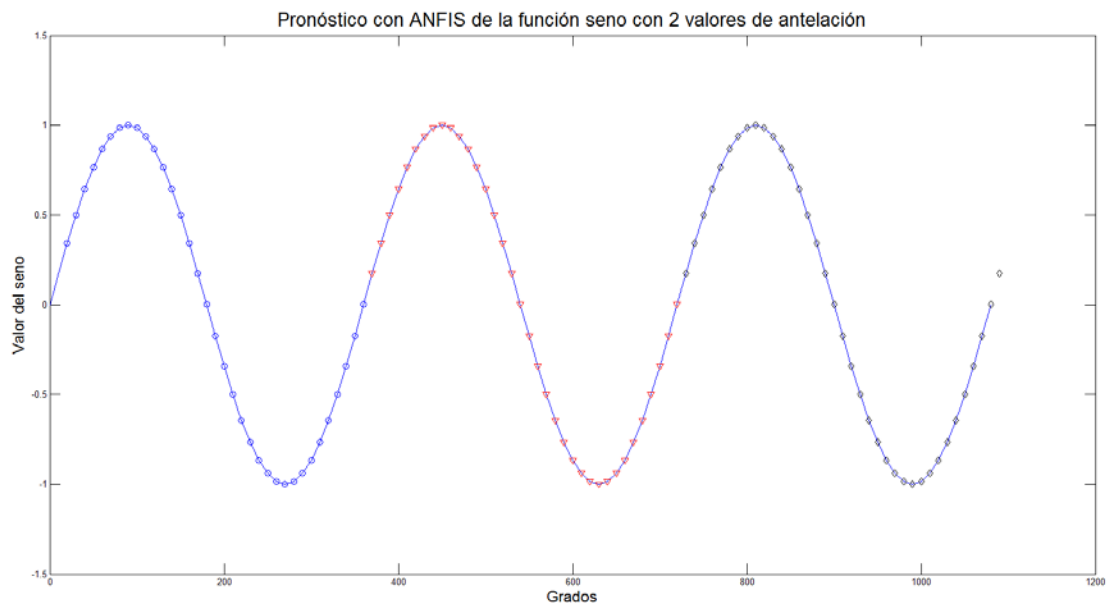


Figura 4.13. Resultados del pronóstico de la función seno con dos valores de antelación empleando ANFIS para tres grupos de datos: entrenamiento, validación y pronóstico.

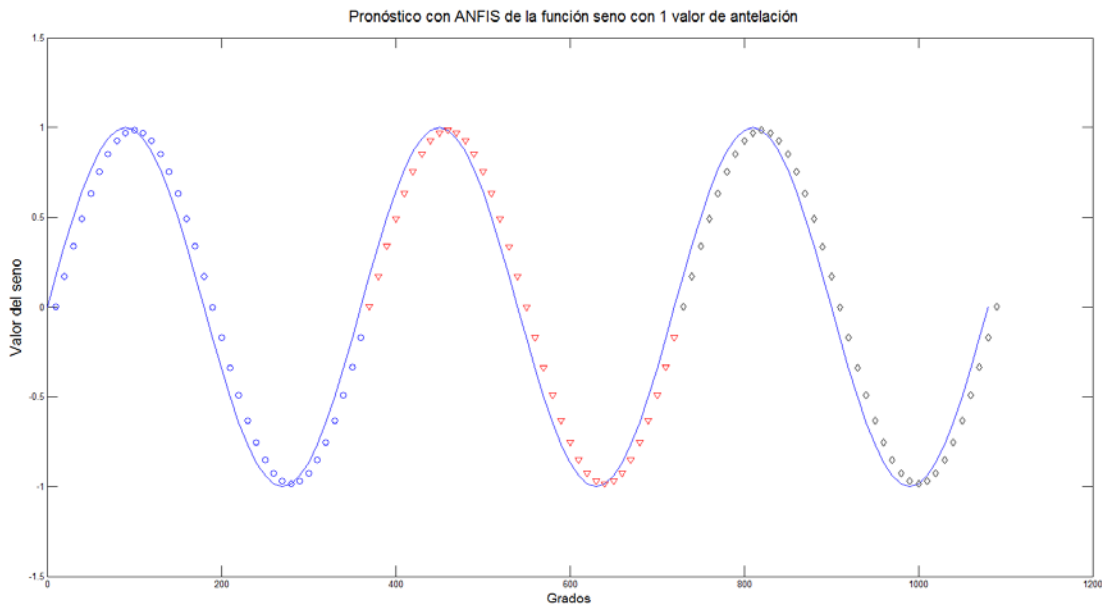


Figura 4.14. Resultados del pronóstico de la función seno con un valor de antelación empleando ANFIS para tres grupos de datos: entrenamiento, validación y pronóstico.

De acuerdo a la Real Academia Española las definiciones de pronóstico y predicción son las siguientes: pronóstico: señal por donde se conjetura o adivina algo futuro; predecir: anunciar por revelación, ciencia o conjetura algo que ha de suceder. De acuerdo a los resultados encontrados y al marco teórico estudiado, el primer y tercer enfoque son ampliamente dependientes del método utilizado para solucionar el relleno para realizar el filtrado, en el sentido estricto se están utilizando valores futuros para realizar el pronóstico, lo que contraviene las definiciones. Para ser más claros, el primer y tercer enfoque utilizan dos predicciones, la primera, cuando se hace el relleno para el filtrado de la señal, en este proceso se inventan al azar, y la segunda cuando se utiliza un algoritmo de pronóstico como *FFBP* o *ANFIS*. Por suerte o casualidad los valores futuro que se requieren para llevar a cabo la convolución y dependen en la mayoría de los casos de lo determinista y la no estacionalidad de la serie de tiempo estudiada, que de acuerdo a la literatura revisada una ventaja de utilizar este tipo de modelado es representar con mayor apego la no linealidad y no estacionalidad de las series de tiempo climáticas.

El segundo enfoque es influenciado por el efecto de borde resultado de la mutilación de algunas de las subseries y el ruido wavelet, este fenómeno es omitido por todos los autores estudiados.

Conclusiones

1. Se generó un modelo para pronosticar la precipitación pluvial en la estación climatológica de Ensenada, B.C. mediante la utilización de la transformada Wavelet, Redes Neuronales Artificiales y Neurodifusas. Con estas técnicas de análisis de señales y de pronóstico se logró realizar diferentes modelos para modelar los registros de la precipitación de la estación Ensenada, estos modelos fueron autónomos e híbridos. Los autónomos consistieron en aplicar un algoritmo de la *CWT* denominado *WMA*, además dos modelos de pronóstico basados en *ANN*, la *FFBP* y *ANFIS*, los híbridos fueron una conjunción entre la *DWT* con dos algoritmos de descomposición y los modelos de pronóstico mencionados arriba, con los cuales se construyeron cuatro modelos híbridos *Mallat-FFBP*, *Mallat-ANFIS*, *MODWT-FFBP* y *MODWT-ANFIS*. Con estos cuatro modelos híbridos se desarrollaron dos enfoques que aparecen en la literatura, el primero de inclusión de variables de entrada a los modelos de pronóstico y el segundo de suavizado. La implementación de estos seis modelos de predicción permitió encontrar que los resultados del primer enfoque tienen una amplia dependencia al método utilizado para el relleno en el proceso de filtrado para realizar la convolución, y en el segundo enfoque se observó que para una serie no-determinista y no-estacionaria el análisis estadístico de los coeficientes de correlación no influye en el resultado final, lo que realmente interviene son las características caóticas y aleatorias de la serie, además existe la presencia de un nuevo efecto de borde y ruido wavelet. De acuerdo a los indicadores de desempeño el Modelo *ANFIS* es que mejor modela los registros de precipitación de la estación Ensenada para el pronóstico de la precipitación.
2. El uso de la transformada wavelet permitió descomponer las series de tiempo de precipitación registradas en la estación Ensenada y encontrar periodicidades en ella, con lo cual se comprobó que es una herramienta útil para el análisis de la serie, debido a que con *WMA* y los algoritmos

- híbridos de pronóstico se llegaron a coincidir aproximadamente con las periodicidades, lo que indica que las descomposiciones ayudan a los algoritmos de pronóstico a mejorar sus indicadores de desempeño.
3. Las metodologías de pronóstico y reconocimiento de patrones como las Redes Neuronales Artificiales y Neurodifusas fueron utilizadas con los datos de precipitación encontrando que *ANFIS* es una herramienta autónoma poderosa pero rígida y la *ANN* empleada *FFBP* es una herramienta versátil pero no logra interpretar el problema. Además deben ser utilizadas considerando las características caóticas y de aleatoriedad de las series de tiempo, asimismo para mejorar los indicadores de desempeño se deben aplicar a series de tiempo cuasi periódicas.
 4. Los indicadores caóticos empleados en esta investigación fueron el exponente de Hurst y el de Lyapunov, debido a que los parámetros estadísticos no representan adecuadamente la no-estacionalidad y no-estacionalidad de la serie climática empleada. El uso de estos indicadores permitió elaborar un escenario coherente sobre los resultados de la investigación, en ese sentido encontrar las fortalezas y debilidades de cada método empleado. En la literatura estudiada no se encontró evidencia de la interpretación de indicadores caóticos aplicados para analizar las series de tiempo climáticas con fines de predicción.

Tomando en cuenta la calidad de la información y representatividad se eligieron los registros de la estación 016 Ensenada para aplicarle los algoritmos antes descritos. Los algoritmos aplicados son la Transformada Wavelet en diferentes modalidades: continua y discretas, en conjunción con las Redes Neuronales Artificiales y Neurodifusas. Finalizada la investigación se obtienen las siguientes conclusiones:

1. De acuerdo al análisis de los escalogramas se puede decir en lo general que en el periodo evaluado existen lluvias similares que se presentan alrededor de 5, 10, 15 y 20 años, aunque en lo particular para el de 5.0 años se comenta que presenta estructuras diferentes en forma y escala, además tiene un periodo seco aproximadamente similar en longitud.

2. De acuerdo a los indicadores caóticos los exponentes de Hurst y Lyapunov indican que las series son prácticamente aleatorias y caóticas respectivamente con una componente significativa de altas frecuencias, por lo tanto de acuerdo a esos criterios se considera que las series de tiempo son impredecibles ya que los parámetros estadísticos no representan ni la aleatoriedad ni las no-estacionalidades.

3. En relación a los métodos autónomos estudiados *ANFIS* reproduce el comportamiento de la serie de precipitación mejor que la *FFBP*, esta última no logra identificar el patrón de variación de la series de precipitación. En el primer enfoque el método de pronóstico con preprocesamiento mostró mejores indicadores de desempeño en el entrenamiento, ya que en el pronóstico influye significativamente en el efecto de borde, acepto para el algoritmo Mallat-*FFBP* implementado con la función wavelet de Haar. Un aspecto fundamental para el pronóstico es no incluir información futura, debido al proceso de convolución de la *TWD* esa información es incluida lo que beneficia al proceso de entrenamiento en el modelado de la serie, sin embargo producto del efecto de borde la información se distorsiona y no se logra un buen pronóstico. Con las pruebas realizadas se demuestra que el coeficiente de correlación de los datos de pronóstico está directamente relacionado con los incluidos para completar la señal necesaria para realizar la convolución y mientras más cercano a uno sea este coeficiente mejor será el desempeño de este proceso. Los mejores resultados para el método WN primer enfoque se obtienen al utilizar el algoritmo Mallat-*FFBP* implementado con la función wavelet de Haar ya que con este wavelet madre no se presenta el efecto de borde.

4. En el segundo enfoque se demuestra que la señal está conformada por una componente significativa de altas frecuencias y ruido corroborados también por los indicadores caóticos exponentes de Hurst y Lyapunov, por lo tanto los algoritmos de predicción no logran modelar hasta que la señal se aproxima a la señal media en los índices de nivel más altos y es necesario eliminar la mayoría de las altas frecuencias en los índices de nivel más bajos. La señal original es constituida en general por altas frecuencias y ruido por esa razón se requiere

descomponerla a un nivel seis que corresponde a un periodo de 5.3 años aproximadamente, esto refuerza lo encontrado en el *WMA* en el análisis de los escalogramas. También se demuestra que en la serie estudiada no-determinista y no estacionaria el nivel de descomposición j no depende del coeficiente de correlación, por eso es importante calcular los exponentes de Hurst y Lyapunov como indicadores caóticos de la serie.

5. Los resultados indican que la *FFBP* y la media de la señal muestran resultados similares en el pronóstico (39.32 mm y 38.91 mm) en términos de *RMSE*, por otra parte el desempeño en la etapa de pronóstico del algoritmo Mallat-*ANFIS* en el primer enfoque es superado por *ANFIS* autónomo en relación al indicador anterior, convirtiéndolo en el mejor método para representar la precipitación y predecirla de nuestra estación en estudio.

6. Los resultados de este trabajo abrieron la posibilidad de continuar las investigaciones en las siguientes líneas:

1. Usar de la información distribuida que presenta el *RADAR* para realizar el pronóstico, estos registros de reflectividad permiten el suavizado de la señal debido a que la precipitación es una variable que fluctúa en tiempo y espacio, a diferencia de las estaciones climatológicas que son punto infinitesimal en el espacio de muestreo de esta variable.
2. Determinar la relación que existe entre los exponentes de Hurst y Lyapunov con el desempeño de los algoritmos de pronóstico para diferentes variables climáticas, con el propósito de definir límite de estos algoritmos para aplicaciones en hidrología.
3. Explorar la utilización de la transformada wavelet *ANN*, *ANFIS* para recuperación de datos faltantes.
4. Utilización de la *CWT* y *DWT* en dos dimensiones en conjunción con la Transformada de Fourier, *ANN* y *ANFIS* para identificar tormentas en imágenes de *RADAR*, con la intención de prevenir eventos extremos.
5. Implementación de técnicas distribuidas invariantes a rotación y escala, empleado Transformada Wavelet, de Fourier, *ANN* y *ANFIS*.

6. Usar la *CWT* en conjunción con la Transformada de Fourier, *ANN* y *ANFIS* para identificar estructuras similares en escalogramas y definir un método para regionalizar la información climatológica.
7. Empleo de *DWT* con el algoritmo de Mallat para fusionar series de tiempo, con finalidad de disminuir el número de estaciones pluviométricas definido por la norma.
8. Medir el desempeño de nuevas técnicas de pronóstico como las *Support Vector Machine SVMs*, para aplicarlas en hidrología.
9. La implementación de la Transformada Wavelet Circular en escalogramas e imágenes de *RADAR*, con fines de predicción.

- ADDISON, P.S., MURRAY, K.B. and WATSON J.N. Wavelet transform analysis of open channel wake flows. *Journal of Engineering Mechanics*, Vol. 127, No.1, January 2001.
- ADDISON P.S. *The Illustrated Wavelet Transform Handbook*, Institute of Physics Publishing, 2002, 353 pp. ISBN 0 7503 0692 0.
- ADAMOWSKI, J.F. Development of short-term river flood forecasting method for snowmelt driven floods based on wavelet and cross-wavelet analysis. *Journal of Hydrology*. Vol. 353, Issues 3-4, pp 247-266, May 2008. doi:10.1016/j.jhydrol.2008.02.013.
- ADAMOWSKI, J. and CHAN, H.F. A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*. Vol. 407, pp 28–40, 2011, doi:10.1016/j.jhydrol.2011.06.013.
- ADAMOWSKI, J. and KARAPATAKI, C. Comparison of Multivariate Regression and Artificial Neural Networks for Peak Urban Water-Demand Forecasting: Evaluation of Different ANN Learning Algorithms. *Journal of Hydrology*. Vol. 15, No. 10, p.p. 729–743, October 1, 2010. doi:10.1016/j.jhydrol.2011.06.013.
- ADAMOWSKI, J. and SUN, K. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. *Journal of Hydrology*, Vol. 390, pp 85–91, 2010, doi:10.1016/j.jhydrol.2010.06.033.
- ASCE (a) Task Committee on Application of Artificial Neural Networks in Hydrology. *Artificial Neural Networks in Hydrology. I: Preliminary Concepts*. *Journal of Hydrologic Engineering*. Vol. 5 No. 2, pp 115-123, April 2000.
- ASCE (b) Task Committee on Application of Artificial Neural Networks in Hydrology. *Artificial Neural Networks in Hydrology. II: Hydrologic Applications*. *Journal of Hydrologic Engineering*. Vol. 5 No. 2, pp 124-137, April 2000.
- BANCO MUNDIAL Y IV FORO MUNDIAL DEL AGUA. Agua para el crecimiento y desarrollo: un marco de trabajo para el análisis. IV Foro Mundial del Agua; Tema 1: Agua para el crecimiento y desarrollo. IV Foro Mundial del Agua, Marzo 2006, 70 pp.
- BRAHM, A. y VARAS, E. Disminución de tiempos de entrenamiento en redes neuronales artificiales aplicadas a hidrología. *Ingeniería Hidráulica en México*. vol. XXIII, núm. 2, pp 69-82, julio-septiembre de 2007.
- BEALE, R. and JACKSON, T. *Neural computing: An introduction*. *Institute of Physics Publishing*. Bristol and Philadelphia, 1990, 240 pp
- BECKER, S., HARTMANN, H., COULIBALY, M., ZHANG, Q. and JIANG, T. Quasi periodicities of extreme precipitation events in Yangtze River basin, China. *Theoretical and Applied Climatology*. Vol. 94, pp 139-152, 2008.
- BESAW, L.E., RIZZO, D.M., BIERMAN, P.R. and HACKETT, W.R. Advances in ungauged streamflow prediction using artificial neural networks. *Journal of Hydrology*. Vol. 386, Issues 1-4, pp. 27-37, May 2010.
- BRUNSELL, N.A. and GILLIES, R. Length Scale Analysis of Surface Energy Fluxes Derived from Remote Sensing. *Journal of Hydrometeorology*, Volume 4 (6), pp. 1212–1219, American Meteorological Society, Aug 7, 2002. doi: 10.1175/1525-7541(2003)004<1212:LSAOSE>2.0.CO;2
- CAMPOS, D.F. Estimación de hidrogramas anuales estacionales en cuencas sin aforos. *Ingeniería Hidráulica en México*. Vol. XX, No. 1 Enero-Marzo 2005. pp. 43-55.
- CAMPOS, D.F. Estudio de la precipitación máxima diaria anual en 53 estaciones pluviométricas del estado de San Luis Potosí mediante el enfoque de región de influencia. *Ingeniería Hidráulica en México*. Vol. XXIII, No. 1 Enero-Marzo 2008. pp. 139-155.
- CANAN S. and YILMAZ D. Chaotic analysis of penicillin induced epileptiform activity rats journal of concrete and applicable mathematics. Vol. 9, No.2, p.p. 154-162, 2011.
- CASTY, C., RAIBLE, C.C., STOCKER, T.F., WANNER, H. and LUTERBACHER, J. A European pattern climatology 1766–2000. *Climate Dynamics*, Vol. 29, pp 791–805, 2007, DOI 10.1007/s00382-007-0257-6.
- CASTLEMAN, K.R. *Digital Image Processing*. Prentice-Hall. Englewood cliffs. New Jersey. 1979.
- CEA, Comisión Estatal del Agua. *Programa Estatal Hidráulico 2003 – 2007*. CEA, México, Septiembre, 2003, 140 pp.

- CEA, Comisión Estatal del Agua. PROGRAMA ESTATAL HÍDRICO 2008 - 2013. CEA, México, 2008, 159 pp.
- CESPT, Comisión Estatal de Servicios Públicos de Tijuana. *Historia de los Acueductos en Tijuana y Playas de Rosarito*. CESPT, México, Marzo 2006. 67 pp.
- CISNEROS, H.L., y PELCZER, I.J. Redes neuronales artificiales para pronosticar alturas de precipitación cada 15 minutos. *Ingeniería Hidráulica en México*. vol. XXII, núm. 3, pp 5-21, julio-septiembre de 2007.
- CLINTON J. Chaos and time series analysis. Oxford, Oxford University Press, 2008. ISBN 978-0-19-850840-3.
- CONAGUA, Comisión Nacional del Agua. *Programa hidráulico Regional 2002-2006: Península Baja California, Región I*. CONAGUA, México, 2003. 192 pp. ISBN 968-817-543-9.
- CONAGUA, Comisión Nacional del Agua. *Información climatológica, Precipitaciones en 24 horas de 1948 al 2011*, archivo electrónico, CONAGUA, Gerencia de Aguas Superficiales e Ingeniería de Ríos, 2011.
- CONAGUA, Comisión Nacional del Agua. *Programa Hídrico Regional Visión 2030: Región Hidrológico-Administrativa I Península de Baja California*. CONAGUA, México, Marzo de 2012, 126 pp. ISBN: 978-607-7908-88-3
- CORNISH, C.R., BRETHERTON, C.S. and PERCIVAL, D.B. Maximal Overlap Wavelet Statistical Analysis With Application to Atmospheric Turbulence. *Boundary-Layer Meteorology*. Vol. 119, Issue 2, p339-374, May2006.
- COULIBALY, P. and BURN, D. H. Spatial and Temporal Variability of Canadian Seasonal Streamflow. *Journal of Climate*. Vol. 18, pp 191-210, January 2005.
- DASTORANI, M.T., AFKHAMI, H., SHARIFIDARANI, H. and DASTORANI, M. Application of ANN and ANFIS models on dryland precipitation prediction (case study: Yazd in Central Iran). *Journal of Applied Sciences*. Vol. 10, Issue_20, pp 2387-2394, 2010, doi: 10.3923/jas.2010.2387.2394
- DAUBECHIES, I. Orthonormal basis of compactly supported wavelets. *Communications on Pure Applied Mathematics*. vol. 41, 1988, pp. 909–996.
- DAUBECHIES, I. The wavelet transform, time-frequency localization and signal analysis. *IEEE Transactions on Information Theory*, vol.36, no.5, September 1990, pp. 961-1005, doi: 10.1109/18.57199.
- DAUBECHIES, I. *Ten Lectures on Wavelets*. *Society for Industrial and Applied Mathematics (SIAM)*. Philadelphia, PA., 341 pp. 1992.
- DEMIREL M.C., BOOIJ, M.J. and KAHYA, E. Validation of an ANN Flow Prediction Model Using a Multistation Cluster Analysis. *Journal of Hydrologic Engineering*, Vol. 17, No. 2, p.p. 262–271, February 1, 2012. ISSN 1084-0699.
- GIANNERINI S. and ROSA R. Assessing Chaos in Time Series: Statistical Aspects and Perspectives. *Studies in Nonlinear Dynamics & Econometrics*. *Studies in Nonlinear Dynamics & Econometrics*. Volume 8, Issue 2, p.p. 1-23, 2004.
- GOLITSYN G. S., EFIMOVA L. K., MOKHOV I. I., RUMYANTSEV V. A., SOMOVA N. G., and KHON V. C. Ladoga and Onega Hydrological Regimes and Their Variations. *Water Resources and the Regime of Water Bodies*. Vol. 29, No. 2, pp. 168–173, 2002.
- GONZÁLEZ, J.M., CERVANTES, R., OJEDA, W. y LÓPEZ, I. Predicción de la evapotranspiración de referencia mediante redes neuronales artificiales. *Ingeniería Hidráulica en México*. vol. XXIII, núm. 1, pp 127-138, enero-marzo de 2008.
- GONZÁLEZ, M., OTAZU, X., FORS, O. and SECO, A. Comparison between Mallat's and the 'à trous' discrete wavelet transform based algorithms for the fusion of multispectral and panchromatic images. *International Journal of Remote Sensing*. Vol. 000, No. 000, Month 2005, pp. 1-19. DOI: 1080/014311605123314056.
- GRAPS, A. An Introduction to Wavelets. *IEEE Computational Science & Engineering*. Vol. 2, No. 2, pp 50-61, Summer 1995.
- GROSSMANN, A. and MORLET, J. Decomposition of Hardy functions into square integrable wavelets of constant shape. *SIAM Journal on Mathematical Analysis*. Vol. 15, Issue 4, pp 723-736, July 1984.
- GUTIÉRREZ, A. y RAMIREZ, A.I. Predicción hidrológica mediante el Método de la Avenida Índice para dos poblaciones. *Ingeniería Hidráulica en México*. Vol. XX, No. 2 Abril-Junio 2005.

pp. 37-47.

HARTMANN, H., BECKER, S. and KING L. Quasi-periodicities in Chinese precipitation time series. *Theoretical and Applied. Climatology*. Vol. 92, pp 155–163, 2008, DOI 10.1007/s00704-007-0317-1.

HURST, H.E., BLACK, R.P., and SIMAIKA Y.M. *Long-Term Storage: An Experimental Study*. Constable, London, 1965.

IMIP, Instituto Municipal de Planeación. *Programa Integral del Agua de Ensenada*. IMIP, Marzo 2008, 132 pp.

IMIP, Instituto Municipal de Planeación. *Programa Integral del Agua del Municipio de Ensenada, B.C*. IMIP, Noviembre 2010, 189 pp.

INE, Instituto Nacional de Ecología. *Cambio global y recursos hídricos en México: hidropolítica y conflictos contemporáneos por el agua*. México, INE, 2002, 107 pp.

INEGI. *Estudio Hidrológico del Estado de Baja California*. INEGI, INEGI, 1995, ISBN 970-13-0739-9.

INEGI, Instituto Nacional de Estadística Geografía e Informática. Aportación al Producto Interno Bruto (PIB) nacional [en línea]. Consultado en la página del INEGI, Disponible en la red en formato aspx: <<http://cuentame.inegi.org.mx/monografias/informacion/bc/economia/pib.aspx?tema=me&e02>>, consultada en Septiembre 2011.

INEGI, México en cifras. Disponible en la red en formato xls: < <http://www3.inegi.org.mx/sistemas/mexicocifras/default.aspx>>, consultada en Septiembre 2012.

INEGI, Instituto Nacional de Estadística Geografía e Informática “Estadísticas a propósito del día mundial de la lucha contra la desertificación y la sequía”, INEGI aguascalientes, ags., a 17 de junio de 2012. 10 pp.

JANG, R.J.S. ANFIS: Adaptive-Network-based Fuzzy Inference Systems, *IEEE Trans. on Systems, Man, and Cybernetics*. vol. 23, pp 665-685, May 1993.

KANTZ, H. A robust method to estimate maximal Lyapunov exponent of a time series. *Physics Letters A*. Vol. 185, Issue 1, p.p. 77-87, 31 Junary 1994.

KANTZ, H. and SCHREIBER, T. *Nonlinear Time Series Analysis*. Cambridge University Press, 365 pp. 1997.

KATUL G.G. and PARLAGE M.B. Analysis of land surface heat fluxes using the orthonormal wavelet approach. *Water Resources Research*. Vol. 31, No. 11, pp. 2743-2749, November 1995.

KATUL G.G., GERON C.D., HSIEH C.I., VIDA KOVIC B. and GUENTHER A.B. Active Turbulence and Scalar Transport Near the Forest-Atmosphere Interfase. *Journal of Applied Meteorology*. Vol. 37, pp. 1533-2749, DEcember 1998.

KIM, T.W. and VALDÉS, J.B. Nonlinear Model for Drought Forecasting Based on a Conjunction of Wavelet Transform and Neural Networks. *Journal of Hydrologic Engineering*. Vol. 8, No. 6, pp. 319-328, November/December 2003.

KIRKUP H., PITMAN A.J., HOGAN J. and BRIERLEY G. An Initial Analysis of River Discharge and Rainfall in Coastal New South Wales, Australia Using Wavelet Transforms. *Australian Geographical Studies*. Vol. 39, No. 3, pp. 313-334. November 2011.

KIŞI, Ö. Neural network and wavelet conjunction model for modelling monthly level fluctuations in Turkey. *Hydrological Processes*. Vol. 23, Issue 14, pp 2081–2092, July 2009, doi: 10.1002/hyp.7340.

LABAT, D.; ABABOU, R.; MANGIN, A. Introduction of Wavelet Analyses to Rainfall/Runoffs Relationship for a Karstic Basin: The Case of Licq-Atherey Karstic System (France). *Ground Water*. Vol. 39, Issue 4, pp. 605-615. Jul/Aug 2001.

LABAT, D. Recent advances in wavelet analyses: Part 1. A review of concepts. *Journal of Hydrology*. Vol. 314, Issue 1-4, pp. 275-288. November 2005, DOI: 10.1016/j.jhydrol.2005.04.003.

LANA, X., MARTÍNEZ, M.D., SERRA, C., AND BURGUEÑO, A. Complex behaviour and predictability of the European dry spell regimes. *Nonlinear. Processes Geophysics*. Vol. 17, p.p. 499–512, 2010. doi:10.5194/npg-17-499-2010.

- LOBODA, N.S., GLUSHKOV, A.V., KHOKHLOV, V.N. AND LOVETT, L. Using non-decimated wavelet decomposition to analyze time variation of North Atlantic Oscillation, eddy kinetic energy, and Ukrainian precipitation. *Journal of Hydrology*. Vol. 322 (2006), pp. 14-24, 2006.
- LORENZ E. Deterministic Nonperiodic Flow. *Journal of Atmospheric Science*. Vol. 20, p.p. 130-141, 1963.
- MA J. and LIU L. Detection of Chaoticity in daily mean temperature time series. *Journal of Systems Science and Information*. Vol. 5, No. 1, p.p. 43-49, 2007.
- MACDONALD, G. and TINGSTAD, A.H. Recent and Multicentennial Precipitation Variability and Drought Occurrence in the Uinta Mountains Region, Utah. *Arctic, Antarctic & Alpine Research*, Vol. 39 Issue 4, pp. 549-555, November 2007.
- MALLAT, S.G. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol. 11, pp 674–693, 1989.
- MALLAT, S. *A. wavelet tour of signal processing, 2nd ed., academic press*, Elsevier 1999, 805 pp.
- MARTÍNEZ, J.B. *Economía de los recursos hidráulicos*. ISPJAE, CUBA, 2000, 115 pp.
- MÉNDEZ, B., DOMÍNGUEZ, R., MAGAÑA, V., CAETANO, E. Y CARRIZOSA, E. Calibración hidrológica de radares meteorológicos. *Ingeniería Hidráulica en México*. Vol. XXI, No. 4 Octubre-Diciembre 2006. pp. 43-64.
- MINOBE, S., MANABE, T. and SHOUJI, A. Maximal Wavelet Filter and Its Application to Bidecadal Oscillation over the Northern Hemisphere through the Twentieth Century. *Journal of Climate*, Vol. 15, Issue 9, pp. 1064-1076, May2002.
- MOLINA, J.P. y APARICIO, J. Transito de avenidas en cauces mediante redes neuronales artificiales. *Ingeniería Hidráulica en México*. vol. XXI, núm. 4, pp. 65-86, octubre-diciembre de 2006.
- MORATA A., MARTÍN M.L., LUNA M.Y. and VALERO F. Self-similarity patterns of precipitation in the Iberian Peninsula. *Theoretical and Applied Climatology*. Vol. 85, pp. 41–59 , 2006. DOI 10.1007/s00704-005-0175-7.
- MWALE, D. and GAN, T.Y. Wavelet Analysis of Variability, Teleconnectivity, and Predictability of the September–November East African Rainfall. *Journal of Applied Meteorology*. Vol. 44 Issue 2, pp. 256-269, February 2005.
- MWALE, D., Gan T.Y., Shen S., Shu T.T. and KIM K.M. Wavelet Empirical Orthogonal Functions of Space-Time-Frequency Regimes and Predictability of Southern Africa Summer Rainfall. *Journal of Hydrologic Engineering*. Vol. 12 No. 5, pp. 513-523, September 2007. ISSN 1084-0699.
- National Oceanic and Atmospheric Administration, NOAA. “Local Climatological Data” 1850 - 2008, San Diego Lindbergh Field, discos compactos, 2008.
- NOLIN A.W. and HALL-MCKIM E.A. Frequency Modes of Monsoon Precipitation in Arizona and New Mexico. Vol. 134, pp. 3774-3781, December 2006.
- NOURANI, V., ALAMI, M.T. and AMINFAR, M.H. A Combined neural-wavelet for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*. Vol. 22, pp 466-472, 2009.
- OCDE, Organización para la Cooperación y el Desarrollo Económicos. *Hacia el crecimiento verde: Un resumen para los diseñadores de políticas*, Paris, Francia, Mayo 2011, 26 pp.
- ONU. *Informe sobre Desarrollo Humano 2006: más allá de la escasez; poder, pobreza y la crisis mundial del agua*, Nueva York, EUA, ONU, 2006, 422 pp. ISBN 10: 84-8476-301-3.
- PARTAL, T. Modelling evapotranspiration using discrete wavelet transform and neural networks. *Hydrological Process*. Vol. 23, pp 3545–3555, 2009, doi: 10.1002/hyp.7448.
- PARTAL, T. and KÜKÜK, M. Long-term trend analysis using discrete wavelet components of annual precipitation measurements in Marnamara region (Turkey). *Physics and Chemistry of the Earth*. Vol. 31, pp. 1189-1200, 2006. doi:10.1016/j.pce.2006.04.043.
- PARTAL, T. and KIŞI, Ö. Wavelet and neuro-fuzzy conjunction model for precipitation forecasting. *Journal of Hydrology*. Vol. 342, Issues 1-2, pp199-212, August 2007, doi:10.1016/j.jhydrol.2007.05.026.

- PERCIVAL, D.B. and WALDEN, A.T. *Wavelet Methods for Time Series Analysis*. Cambridge University Press, Cambridge, 2000, 594 pp. ISBN 0521 64068 7.
- PÉREZ J.V. TORRA S. Reversión a la media, no linealidad y cambios de régimen en la evolución temporal del Ibex35. *Revista Española de Financiación y Contabilidad*. Vol. XXXII, No. 119, p.p. 1177-1203, Octubre-Diciembre 2003.
- PIZARRO, R. *Elementos técnicos de hidrología III*. Proyecto regional mayor sobre conservación de recursos hídricos en áreas rurales de América Latina y el Caribe. Talca, Chile, Universidad de Talca. 135 pp. 1993.
- PLU, M.; ARBOGAST, P. AND JOLY, A. A Wavelet Representation of Synoptic-Scale Coherent Structures. *Journal of the Atmospheric Sciences*. Vol. 65, Issue 10, p3116-3138, Oct2008.
- PURANIK, D.M. AND KAREKAR, R. N. Precursors to Convection over Peninsular India during March–May in AMSU-B Data. *Weather & Forecasting*. Vol. 21, Issue 5, p.p. 781-801, October 2006.
- Quintas, I. e IMTA Instituto Mexicano de Tecnología del Agua. “Extractor Rápido de Información Climatológica II, ERIC II, disco compacto, ISBN 9 6874 1740 4. 2000.
- RAJAEI, T., NOURANI, V., ZOUNEMAT, M. and KISI, O. River Suspended Sediment Load Prediction: Application of ANN and Wavelet Conjunction Model. *Journal of Hydrologic Engineering*. Vol. 16, No. 8, p.p. 613–627, August 1, 2011. ISSN 1084-0699.
- RAMACHANDRA A. AND BHATTACHARYA D. Comparison of Hurst exponent estimates in hydrometeorological time series. *Journal of Hydrologic Engineering*. Vol. 4, No. 3, p.p. 225-231, July 1999.
- REHMAN, S. AND SIDDIQUI, A.H. Wavelet based Hurst exponent and fractal dimensional analysis of Saudi climatic dynamics. *Chaos Solutions and Fractals*. Vol. 40, pp. 1081-1090, 2009.
- REISS, J.D., DJUREK, I., PETOSIC, A. and DJUREK, D. Verification of chaotic behavior in an experimental loudspeaker. *Journal Acoustical Society of America*. Vol. 124, Issue 4, p.p. 2031–2041, October 2008.
- REMESAN, R., SHAMIM M.A., HAN D. and MATHEW J. Runoff prediction using an integrated hybrid modelling scheme. *Journal of Hydrology*. Volume 372, Issues 1-4, p.p. 8-60, June 2009.
- ROUSSEAU P.A., INFANTE S.O., HERNÁNDEZ J. e INZUNZA E. Análisis de correlación de datos de lluvia mediante la transformada wavelet. XXI Congreso Latinoamericano de Hidráulica. Sao Paulo, Brasil, Noviembre 2004.
- ROUSSEAU P.A. *Política de operación y destino de la presa Emilio López Zamora en Ensenada, Baja California, México*, ISPJAE, Centro de Investigaciones Hidráulicas. Tesis de Maestría, 2001.
- RUSI, Royal United Services Institute. *Cambio climático, migración y seguridad: política de mejores prácticas y opciones operacionales para México*. Londres, Reino Unido, RUSI, Noviembre 2011, 40 pp.
- SAINZ, J. Y BECERRA, M. Los conflictos por agua en México: avances de investigación [en línea]. Consultado en la pagina del INE Instituto Nacional de Ecología en Septiembre 2012. Disponible en la red en formato pdf: <http://www2.ine.gob.mx/publicaciones/gacetas/389/conf_agua.html>.
- SEDECO, Secretaria de Desarrollo Económico del Gobierno del Estado de Baja California. Estadística, Secretaria de Desarrollo Económico [en línea]. Consultado en la pagina de SEDECO en Septiembre 2012, Disponible en la red en formato html: <<http://www.bajacalifornia.gob.mx/sedeco/estadisticas/index.html>>.
- SEMARNAT, Secretaria de Marina Recursos Naturales. *Programa de Ordenamiento Ecológico Marino y Regional del Pacífico Norte: I.A. Caracterización Componente Natural*. SEMARNAT, México. 2012, p.p. 21.
- SEN A.K., LITAK, G. and SYTA, A. Cutting process dynamics by nonlinear time series and wavelet analysis. *Chaos*. Vol. 27, Issue 023133, p.p. 1-8, 2007.
- SHIRI, J. and KISI O. Short-term and long-term streamflow forecasting using a wavelet and neuro-fuzzy conjunction model. *Journal of Hydrology*. Vol. 394, pp. 486-493, 2010. doi:10.1016/j.jhydrol.2010.10.008.

- SILVERMAN, D. and DRACUP. Artificial Neural Networks and Long-Range Precipitation Prediction in California. *Journal of Applied Meteorology*. Vol. 39, pp 57-66, 2000.
- SMITH, M.B.; KOREN, V.I.; ZHANG, Z.; REED, S.M.; PAN, J.; MOREDA, F. Runoff response to spatial variability in precipitation: an analysis of observed data. *Journal of Hydrology*. Vol. 298, Issue 1-4, pp.267-286, DOI: 10.1016/j.jhydrol.2004.03.039, 2004.
- THOMAS, C. AND FOKEN, T. Detection of long-term coherent exchange over spruce forest using wavelet analysis. *Theoretical & Applied Climatology*. Vol. 80, Issue 2-4, pp.91-104, 14p, 2005. DOI: 10.1007/s00704-004-0093-0.
- TIWARI, M.K. and CHATTERJEE, C. Development of an accurate and reliable hourly flood forecasting model using wavelet–bootstrap–ANN (WBANN) hybrid approach. *Journal of Hydrology*, Vol. 394, Issues 3-4, pp 458-470, November 2010.
- TORRENCE, C. Y COMPO, G.P. A Practical Guide To Wavelet Analysis. *Bulletin of the American Meteorological Society*. Vol. 79, No 1, January 1998, pp. 61-78.
- TORRENCE, C. Y WEBSTER, P. Interdecadal Changes in the ENSO-Monsoon System, *Journal of Climate*, American Meteorological Society. Vol. 12: 2679-2690, Aug. 1999.
- TORRES, J. E INFANTE, S.O. Wavelet Analysis for the elimination of striping noise in satellite images. *Optical Engineering*, Vol. 40(7), pp.1309-1314, 2001.
- TURNER, B. J.; ZAWADZKI, I.; GERMANN, U. Predictability of Precipitation from Continental Radar Images. Part III: Operational Now casting Implementation (MAPLE). *Journal of Applied Meteorology*. Vol. 43, Issue 2, pp.231-248, Feb. 2004.
- UESUGI, F., TANAKA, Y. and HORIO, Y. Influences of Nonideal Characteristics of A-D Converter on Estimation of the Lyapunov Exponent of One-Dimensional Discrete-Time Dynamical Systems. *Electronics and Communications in Japan*, Part 3, Vol. 83, No. 10, p.p. 74-81, 2000.
- UNESCO. *Water in a changing world: The United Nations world water development report 3*, Paris, France, UNESCO, 2009, 318 pp. ISBN: 978-9-23104-095-5.
- VARGAS, E. Daños por mil mdp tras lluvias. *Periódico El Vigía*, II Época. No. 2600, 54 pp. Viernes 12 de Febrero de 2010.
- WANG, S., FENG, J. and LIU, G. Application of seasonal time series model in the precipitation forecast. *Mathematical and Computer Modelling*. Article in Press. 2012.
- WOLF, A., SWIFT, J., SWINNEY H.L. and VASTANO J.A. Determining Lyapunov exponents from a time series. *Physica D: Nonlinear Phenomena*. Vol. 16, Issue 3, p.p. 285–317, July 1985.
- WU, C.L., CHAU, K.W., and LIA, Y.S. Methods to improve neural network performance in daily flows prediction. *Journal of Hydrology*. Vol. 372, Issues 1-4, pp 80-93, June 2009.
- WU, C.L., CHAU, K.W. and FAN, C. Prediction of rainfall time series using modular artificial neural networks coupled with data-preprocessing techniques. *Journal of Hydrology*. Volume 389, Issues 1-2, pp 146-167, July 2010.
- XUE Y., SUN S., LAU K.M., JI J., POCCARD I., ZHANG R., KANG H.S., WU G., SCHAAKE J.C., ZHANG J.Y. and JIAO Y. Multiscale Variability of the River Runoff System in China and Its Long-Term Link to Precipitation and Sea Surface Temperature. *Journal of Hydrometeorology*. Vol. 6, pp. 550-570, 2005.
- YOKOI, S. and SATOMURA, T. An Observational Study of Intraseasonal Variations over Southeast Asia during the 1998 Rainy Season. *Monthly Weather Review*. Vol. 133, Issue 7, pp. 2091-2104, July 2005.
- YOKOI, S., SATOMURA, T., and MATSUMOTO J. Climatological Characteristics of the Intraseasonal Variation of Precipitation over the Indochina Peninsula. *JOURNAL OF CLIMATE*. Vol. 20, p.p.5301-5315, November 2007.

Apéndice A
Información RADAR

De acuerdo a Rosengaus (2006) entre los datos más codiciados por un hidrólogo o un ingeniero hidráulico siempre han estado la evolución en el tiempo y la distribución espacial de la precipitación dentro de una cuenca de interés. En México este tipo de información ha permanecido fuera del alcance de los especialistas. Por ello los métodos y herramientas usuales se fundamentan en datos más elementales, como la lluvia registrada en intervalos de 24 horas en unos puntos aislados de la cuenca. El *RADAR* meteorológico es un instrumento de observación atmosférica específicamente orientado a la vigilancia continua (en tiempo y espacio) de la precipitación pluvial.

Con referencia a la *NOAA (2012)* el *RADAR* que significa *Radio Detection And Ranging* es la herramienta más eficaz para detectar precipitación. Se ha utilizado para detectar principalmente precipitaciones y tormentas eléctricas, desde la década de 1940. El *RADAR* ha tenido mejoras tecnológicas lo que ha permitido al *National Weather Service (NWS)* examinar las tormentas con mayor precisión. El *RADAR* utilizado por el *NWS* es un modelo WSR-88D, que significa *Weather Surveillance RADAR - 1988 Doppler*, debido a que el radar prototipo fue construido en 1988. Doppler significa que puede detectar movimientos hacia o desde el radar, así como la ubicación de las zonas de precipitación. Existen 155 WSR-88D radares Doppler en EUA, que administra el *NWS* y el Departamento de Defensa de los EUA (Figura A.1).

La antena del *RADAR* emite ráfagas muy cortas de ondas de radio llamadas pulsos. Cada pulso dura aproximadamente 0.00000157 segundos, con un periodo de escucha de 0.00099843 segundo. Las ondas de radio transmitidas se mueven a través de la atmósfera aproximadamente a la velocidad de la luz. Las gotas de lluvia, granizo, etc., reflejan las ondas de radio o ecos. Entre mayor sea el reflejo más grandes son las partículas y/o su densidad. Los pulsos de WSR-88D cuentan con una potencia media de transmisión de cerca de 450000 vatios.

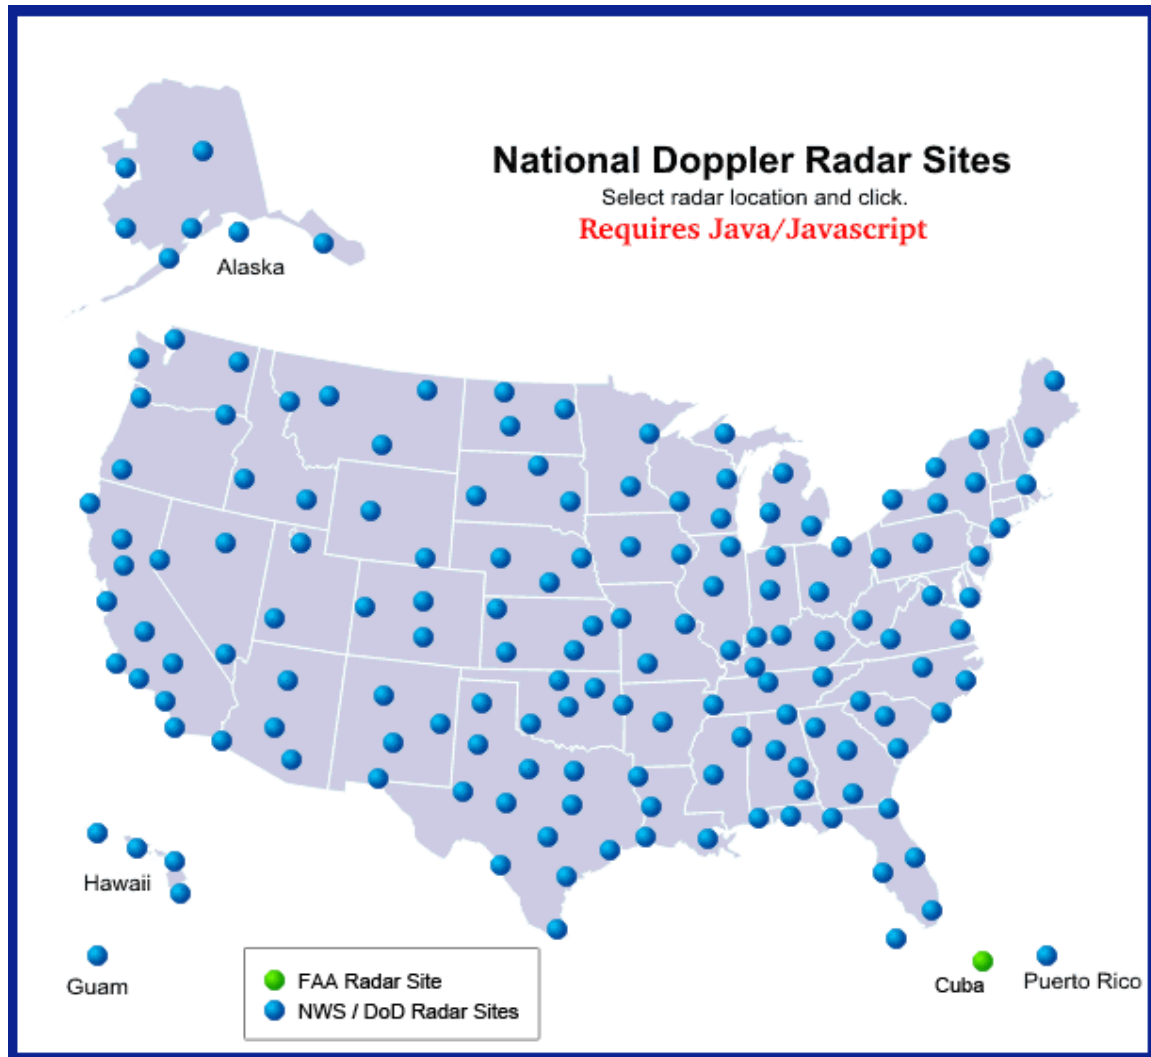


Figura A.1. Radares Doppler en EUA modelo WSR-88D, que administra el NWS y el Departamento de Defensa de los EUA.

El WSR-88D emplea estrategias de exploración en la que la antena aumenta automáticamente a más y más altos ángulos preestablecidos, o rebanadas de elevación, a medida que gira también en ángulos preestablecidos. Estas rebanadas de elevación comprenden un *Volume Coverage Patterns VCP* y existen diferentes modos, por ejemplo para el modo de precipitación *VCP11* existen 14 ángulos de elevación (0.5, 1.5, 2.4, 3.4, 4.3, 5.3, 6.2, 7.5, 8.7, 10, 12, 14, 16.7, 19.5 grados) y recorre 16 veces la circunferencia de 360° en 5 minutos.

El *NWS* ofrece varias imágenes diferentes de la red de radares Doppler. Hay dos tipos de imágenes disponibles en la web, la base de reflectividad (0.5 grados de elevación) y la reflectividad compuesta. La base de reflectividad es la imagen principal predeterminada y se utiliza para representar la precipitación. Hay dos versiones de la imagen de la base de reflectividad; la versión de corto alcance que se extiende por un radio de aproximadamente 230 km y la versión de largo alcance que se extiende por un radio de aproximadamente 400 km. Las imágenes de reflectividad compuestas utilizan todas las elevaciones durante cada barrido, esto permite ver la información sobre los picos de las montañas, ya que la base de reflectividad a menudo no es lo suficientemente elevada para ver por encima de las cordilleras.

Las intensidades reflejadas por los ecos del *RADAR* se miden en *dBz*. (decibeles de *z*), a mayor potencia reflejada de la señal devuelta al *RADAR* se incrementan los valores de *dBz*. El *RADAR* Doppler no determina donde se encuentra la lluvia, solamente devuelve las áreas de energía. La escala de *dBz* es logarítmica y es adimensional (ecuación A.1).

$$dBz = 10 \log(z/z_0) \quad (A.1)$$

donde *z* es la relación de la densidad de gotas de agua y se llama factor de reflectividad (en mm^6/m^3) y z_0 es definida como $1 mm^6/m^3$. Cuando la *z* es grande existen muchas gotas por metro cúbico y la potencia reflejada es grande al contrario un valor de *z* pequeño significa que la energía devuelta es menor.

La escala de valores de *dBz* también está relacionada con la intensidad de las precipitaciones. Normalmente, la lluvia se produce cuando el valor alcanza el 20 *dBz* (Tabla A.1). En los valores aproximadamente entre 60 a 65 *dBz* las interpretaciones pueden tener errores y se puede subestimar o sobreestimar las tormentas debido a diferentes factores como: presencia de granizo y condiciones atmosféricas principalmente. Ver imagen en la figura A.2 que muestra la base de reflectividad del *RADAR* ubicado en el condado de San Diego, EUA.

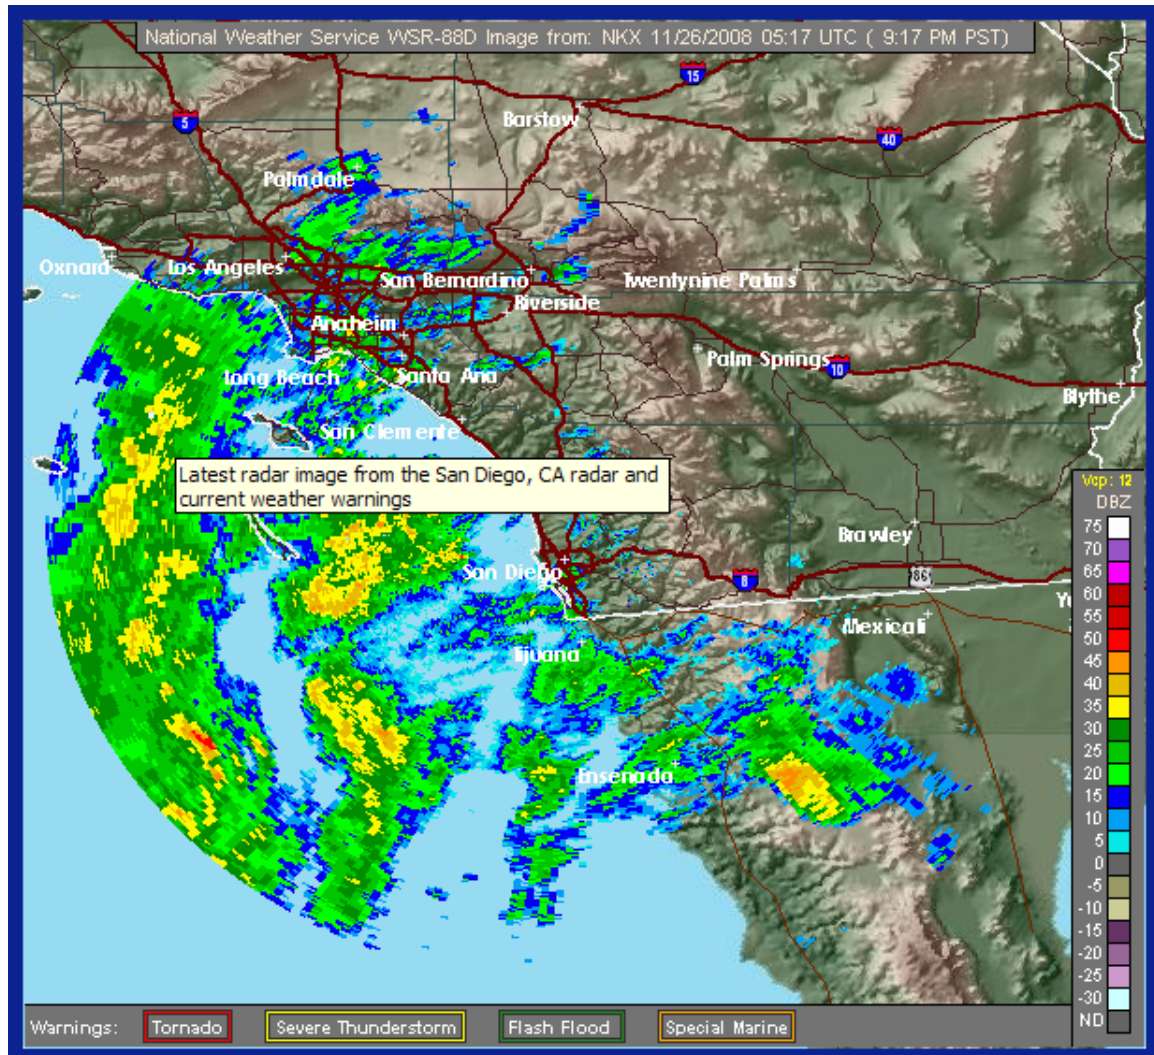


Figura A.2. RADAR Doppler ubicado en el condado de san Diego, EUA. La imagen es obtenida el 26 de Noviembre del 2008 a las 9 horas con 17 minutos y presenta una advertencia de precipitación.

La imagen muestra la base de reflectividad del *RADAR* Doppler. Los colores representan la fuerza de energía que regresa al radar expresada en valores de decibeles *dBz*. La escala de color se encuentra en la parte inferior derecha de cada imagen.

La base de reflectividad es excelente para que el *RADAR* busque precipitación. Sin embargo, se debe tomar en cuenta que la haz emitida por el *RADAR* aumenta en la elevación, así mismo aumenta la distancia del *RADAR* al punto de muestra. Considerando la geodesia el *RADAR* llega a subestimar la fuerza y la intensidad de las tormentas lejanas. Por esta razón, es aconsejable consultar

siempre las imágenes de *RADAR* desde diferentes lugares para ayudar a proporcionar el panorama general de las condiciones meteorológicas en una zona determinada.

Tabla A.1. Relación entre los *dBz* y la intensidad de la lluvia en *mm/h*. El valor de 20 *dBz* es cuando aproximadamente inicia la precipitación.

<i>dBz</i>	Intensidad de la lluvia (<i>mm/hr</i>)
65	406.40
60	203.20
55	101.60
52	63.50
47	31.75
41	12.70
36	6.35
30	2.54
20	Empieza a llover
Menor que 20	No hay lluvia

Según Méndez et al. (2006) debido a la dificultad para determinar la distribución de tamaños de de las gotas dentro del volumen muestreado, se han obtenido diversas relaciones del tipo:

$$z = AR^b; \tag{A.2}$$

donde *z* es la reflectividad en mm^6/m^3 , *A* y *b* son parametros y *R* es la intensidad de la lluvia en *mm/hr*. Las relaciones más conocidas en la literatura para diferentes tipos de lluvia se presentan en la Tabla A.2.

La *National Oceanic and Atmospheric Administration (NOAA)* a través *National Climatic Data Center (NCDC)* proporciona un acceso a los datos históricos del *RADAR*, además suministra un programa denominado *Weather and Climate Toolkit version 2.5.0 (WCT 2.5.0)* para visualizar los valores de reflectividad, sin embargo es difícil acceder a los datos de reflectividad y a la fecha no se cuenta

con los recursos en software y hardware para poderlos manipular, además las información presenta ruido de acuerdo a los archivos observados. En las Figuras A.3 y A.4 se presenta la implementación del programa *WCT* 2.5.0, en ellas se observa la base de reflectividad del día 30 de Marzo de 1997, en los instantes que el *RADAR* registra ruido hasta el momento desconocido.

Tabla A.2. Relación entre los tipos de lluvia y la fórmula de reflectividad en función de la intensidad de la lluvia en *mm/h*. El valor de 20 *dBz* es cuando aproximadamente inicia la precipitación.

Tipo de lluvia	Intensidad de la lluvia (mm/h)
Estratiformes	$z = 200R^{1.6}$
Orográficas	$z = 31R^{1.71}$
Convectivas	$z = 486R^{1.37}$

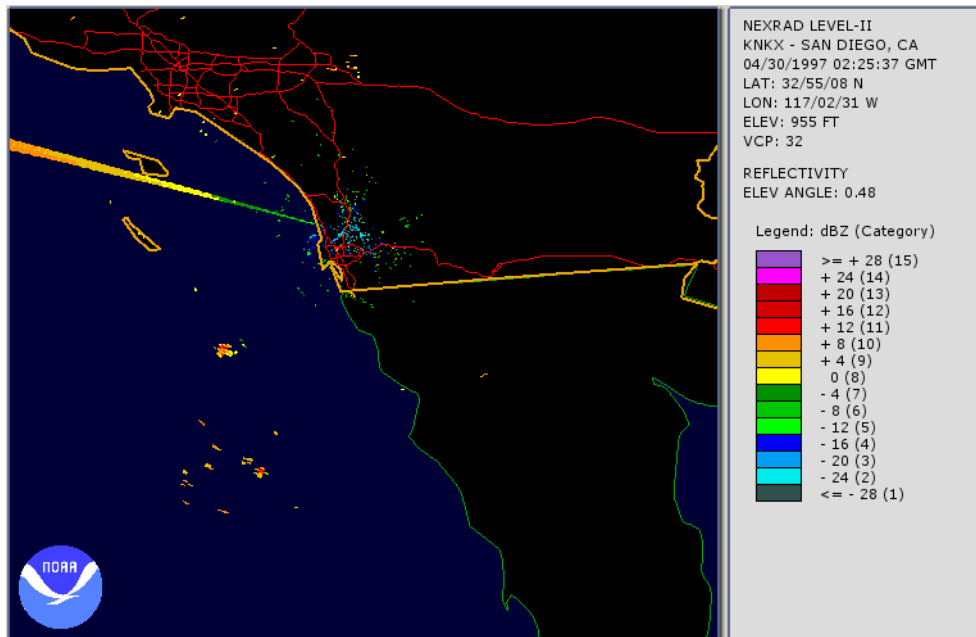


Figura A.3. Implementación del programa *WCT* 2.5.0 para la información del RADAR Doppler ubicado en el condado de san Diego, EUA. En la imagen (04/30/1997, 02:25:37 horas) se observa ruido hasta el momento desconocido.




Figura A.4. Implementación del programa *WCT 2.5.0* para la información del RADAR Doppler ubicado en el condado de san Diego, EUA. En la imagen (04/30/1997, 07:09:55 horas) se observa ruido hasta el momento desconocido.

Apéndice B

Coeficientes de escalamiento y wavelet

La suavidad del wavelet es asociada con una condición de momento (ecuación B.1) que puede ser expresada en términos de los coeficientes de escalamiento $\phi(t)$ cuyos elementos se denominan h_l :

$$\sum_{l=0}^{L-1} (-1)^l h_l l^z = 0 \quad (\text{B.1})$$

donde L = número de coeficientes de escalamiento; $l = 0, 1, 2, \dots, L - 1$ y $z = 0, 1, 2, \dots, L/2 - 1$, estos wavelet tienen $L/2$ momentos de desvanecimiento y son polinomiales hasta el grado $L/2 - 1$. Las longitudes de soporte del wavelet de Daubechies es $L - 1$, por ejemplo Daubechies de orden dos conocido también como wavelet de Haar, que tiene un soporte de longitud uno. En nuestro caso de Daubechies de orden cuatro (Db4) tiene un soporte de longitud tres. La función de escalamiento $\phi(t)$ permite infiltrar a las frecuencias más bajas y por tanto actúa como un filtro pasa bajas h (ecuación B.2). La función wavelet $\psi(t)$ asociada a $\phi(t)$ permite infiltrar a las frecuencias más altas y por tanto es un filtro pasa altas (ecuación B.3).

$$\phi(t) = \sum_{l=0}^{L-1} h_l \phi(2t - l) \quad (\text{B.2})$$

La función wavelet $\psi(t)$ asociada a $\phi(t)$ permite infiltrar a las frecuencias más altas y por tanto es un filtro pasa altas.

$$\psi(t) = \sum_{l=0}^{L-1} (-1)^l h_{L-1-l} \phi(2t - l) \quad (\text{B.3})$$

Para encontrar los valores de los coeficientes de los coeficientes de escalamiento para Daubechies de orden cuatro, se debe satisfacer las siguientes condiciones:

$$\sum_{l=0}^{L-1} h_l = 2 \quad (\text{B.4})$$

Y con el propósito de crear una malla ortogonal se debe satisfacer la siguiente condición:

$$\sum_{l=0}^{L-1} h_l h_{l+l'} = \begin{cases} 2 & \text{si } l' = 0 \\ 0 & \text{en otro caso} \end{cases} \quad (\text{B.5})$$

Las tres ecuaciones (B.1, B.4 y B.5) sirven para encontrar los coeficientes wavelet de Daubechies utilizando diferentes condiciones de frontera.

Utilizando la ecuación B.1 con la condición de frontera para $z = 0$, se tiene:

$$h_0 - h_1 + h_2 - h_3 = 0 \quad (\text{B.6})$$

Empleando la ecuación B.1 con la condición de frontera para $z = 1$, se tiene:

$$0h_0 - 1h_1 + 2h_2 - 3h_3 = 0 \quad (\text{B.7})$$

el caso de cuatro coeficientes de Daubechies utilizando la ecuación B.4, se obtiene:

$$h_0 + h_1 + h_2 + h_3 = 2 \quad (\text{B.8})$$

Utilizando la ecuación B.5 se obtiene:

$$h_0^2 + h_1^2 + h_2^2 + h_3^2 = 2 \quad (\text{B.9})$$

Los cuatro coeficientes de escalamiento $\phi(t)$ de Daubechies de orden 4 se obtienen al resolver el sistema de ecuaciones B.6, B.7, B.8 y B.9, resultando:

$$h_0 = \frac{1+\sqrt{3}}{4} ; h_1 = \frac{3+\sqrt{3}}{4} ; h_2 = \frac{3-\sqrt{3}}{4} ; h_3 = \frac{1-\sqrt{3}}{4}$$

o bien,

$$h_0 = 0.6830127$$

$$h_1 = 1.1830127$$

$$h_2 = 0.3169873$$

$$h_3 = -0.1830127$$

Considerando la constante $1/\sqrt{2}$ de la ecuación 2.13, se obtiene el filtro pasa altas h que aparece en la ecuación 2.21.

Mediante la ecuación B.10 se pueden calcular los elementos de los coeficientes de coeficientes wavelet g_l a partir de los elementos c_l de los coeficientes de escalamiento:

$$g_l = (-1)^l c_{L-1-l} \quad (\text{B.10})$$

Aplicando la ecuación B.9 se obtienen los cuatro coeficientes de wavelet g_l de Daubechies de orden 4, resultando:

$$g_0 = \frac{1-\sqrt{3}}{4} ; g_1 = \frac{-3+\sqrt{3}}{4} ; g_2 = \frac{3+\sqrt{3}}{4} ; g_3 = \frac{-1-\sqrt{3}}{4}$$

Considerando la constante $1/\sqrt{2}$, se obtiene el filtro pasa bajas g que aparece en la ecuación 2.22.

