

**UNIVERSIDAD NACIONAL DE PIURA**

**FACULTAD DE INGENIERÍA INDUSTRIAL**

**ESCUELA PROFESIONAL DE INGENIERÍA INDUSTRIAL**



**TESIS**

**“MODELAMIENTO DEL PRONÓSTICO DEL FENÓMENO EL NIÑO  
EN PIURA APLICANDO REDES NEURONALES ARTIFICIALES”**

**PRESENTADO POR:**

**JORGE LUIS CELI PINZÓN**

**TESIS PARA OPTAR EL TÍTULO DE**

**INGENIERO INDUSTRIAL**


**PIURA PERÚ**

**2016**

**UNIVERSIDAD NACIONAL DE PIURA**  
**FACULTAD DE INGENIERÍA INDUSTRIAL**  
**ESCUELA PROFESIONAL DE INGENIERÍA INDUSTRIAL**

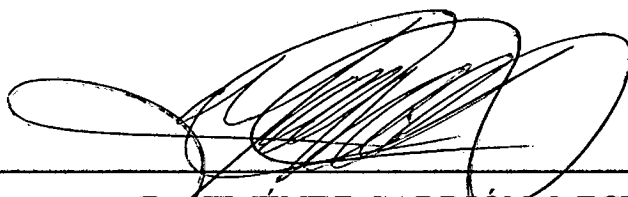
**TESIS**

**“MODELAMIENTO DEL PRONÓSTICO DEL FENÓMENO EL NIÑO EN PIURA  
APLICANDO REDES NEURONALES ARTIFICIALES”**



---

**Bach. CELI PINZÓN, JORGE LUIS**  
Tesista



---

**Dr. JIMÉNEZ CARRIÓN, MIGUEL**  
Asesor



---

**MSc. MADRID GUEVARA, FERNANDO**  
Co - Asesor

**UNIVERSIDAD NACIONAL DE PIURA**  
FACULTAD DE INGENIERÍA INDUSTRIAL  
ESCUELA PROFESIONAL DE INGENIERÍA INDUSTRIAL

**TESIS**

“MODELAMIENTO DEL PRONÓSTICO DEL FENÓMENO EL NIÑO EN PIURA  
APLICANDO REDES NEURONALES ARTIFICIALES”

Aprobada Por:

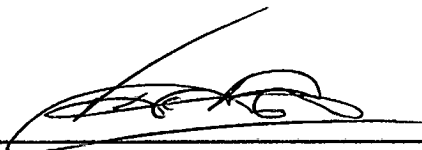


---

MSc. PABLO DELGADO DÍAZ  
Presidente – Jurado Calificador

---

MSc. CARMEN ZULEMA QUITO RODRÍGUEZ  
Vocal – Jurado Calificador




---

MSc. VICTOR HUGO VALLE RÍOS  
Secretario – Jurado Calificador



**UNIVERSIDAD NACIONAL DE PIURA  
FACULTAD DE INGENIERIA INDUSTRIAL  
DECANATO**



**ACTA DE SUSTENTACIÓN DE TESIS**

Los Miembros del Jurado Calificador de la Tesis denominada: «**MODELAMIENTO DEL PRONÓSTICO DEL FENÓMENO DEL NIÑO EN PIURA APLICANDO REDES NEURONALES ARTIFICIALES**»; presentado por **JORGE LUIS CELI PINZÓN**, Bachiller en **INGENIERÍA INDUSTRIAL**, asesorado por el Dr. **MIGUEL JIMÉNEZ CARRIÓN** y co asesorado por el **MSc. FERNANDO MADRID GUEVARA**, Reunidos para la sustentación de ésta y luego de escuchar su exposición y las respuestas a las preguntas formuladas, la declaran:



Con el Calificativo:

..... **APROBADO** .....

..... **MUY BUENO** .....

En consecuencia el sustentante se encuentra **apto** para recibir el título profesional de **INGENIERO INDUSTRIAL** conforme a Ley.

Piura, 16 de Diciembre del 2016

*[Signature]*

**MSc. PABLO DELGADO DÍAZ**  
PRESIDENTE – JURADO CALIFICADOR

*[Signature]*

**MSc. CARMEN ZULEMA QUITO RODRÍGUEZ**  
VOCAL – JURADO CALIFICADOR

*[Signature]*

**MSc. VÍCTOR HUGO VALLE RÍOS**  
SECRETARIO – JURADO CALIFICADOR

## **DEDICATORIA**

Dedico la presente tesis a mis padres, que con su esfuerzo, apoyo y consejo han sabido educarme y motivarme para ser una mejor persona, alentándome siempre a cumplir mis metas y a buscar siempre la felicidad.

## **AGRADECIMIENTOS**

En primer lugar, te agradezco a ti Dios, por ayudarme a terminar este proyecto, gracias por darme la fuerza, coraje y paciencia para hacer este sueño realidad, por estar conmigo en cada momento de mi vida y por mantenernos con bien.

A mis asesores, Dr. Miguel Jiménez Carrión y MSc. Fernando Madrid Guevara quienes me guiaron en la realización de la presente tesis. Les doy infinitas gracias porque siempre tuvieron la paciencia y la comprensión necesaria para responder mis dudas, cuestionamientos e inquietudes durante la realización de esta tesis.

A los docentes de la Facultad de Ingeniería Industrial por todos los conocimientos impartidos a lo largo de nuestra formación académica profesional.

A Karoline Palacios, por todos los momentos que hemos compartidos, por su apoyo incondicional, sus enseñanzas y su compañía durante toda esta aventura universitaria.

A mis compañeros, por todas las experiencias que pasamos dentro y fuera del salón de clases.

A mi familia, por ser mi fuente de motivación e inspiración para superarme constantemente.

# CONTENIDO

RESUMEN	xiii
ABSTRACT	xiv
Capítulo I: INTRODUCCIÓN	1
1.1. Planteamiento del problema	1
1.2. Objetivos	2
1.2.1. Objetivo general	2
1.2.2. Objetivos específicos	2
1.3. Justificación, importancia y beneficiarios	2
1.3.1. Justificación	2
1.3.2. Importancia	3
1.3.3. Beneficiarios	3
1.4. Hipótesis: general y específicas	4
1.4.1. Hipótesis general	4
1.4.2. Hipótesis específicas	4
Capítulo II: MARCO TEÓRICO	5
2.1. Ubicación y descripción geográfica de Piura	5
2.1.1. Clima	6
2.1.2. Topología del suelo	6
2.2. Fenómeno El Niño	6
2.2.1. ¿Cómo se produce?	7
2.2.2. Corriente El Niño	8
2.2.3. Condiciones normales y condiciones El Niño	8
2.2.4. Regiones El Niño	9
2.2.5. Fenómeno El Niño de 1982 – 1983	10
2.2.6. Fenómeno El Niño de 1997 – 1998	12
2.3. Estudio de los modelos de pronósticos	14
2.3.1. Enfoques para la elaboración de pronósticos	14
2.3.2. Pronósticos basados en series de tiempo	15
2.3.3. Componentes de una serie de tiempo	15
2.3.4. Modelos clásicos de series de tiempo	16
2.3.5. Medición del error de pronóstico	16
2.3.6. Modelo de Winters	18

2.4.	Redes neuronales artificiales	23
2.4.1.	El modelo de la red neuronal	23
2.4.2.	Caracterización de las redes neuronales	25
2.4.3.	Diseño y construcción de redes neuronales	27
2.4.4.	Elementos básicos que componen una red neuronal	28
2.4.5.	Validación de una red neuronal	31
2.4.6.	Principales topologías de las redes neuronales artificiales	32
2.4.7.	Aplicaciones de las redes neuronales artificiales	34
<b>Capítulo III: MATERIALES Y MÉTODOS</b>		<b>38</b>
3.1.	Tipo y nivel de la investigación	38
3.2.	Modelo teórico	38
3.3.	Diseño de la investigación	40
3.4.	Identificación de variables	44
3.5.	Muestra	46
3.6.	Método de análisis de datos	46
<b>Capítulo IV: RESULTADOS Y DISCUSIÓN</b>		<b>47</b>
4.1.	Observación de la serie meteorológica	47
4.1.1.	Precipitaciones en Piura	47
4.1.2.	Comportamiento de la temperatura superficial del mar en la formación del fenómeno El Niño	50
4.1.3.	Comportamiento de la velocidad de los vientos alisios en la formación del fenómeno El Niño	57
4.1.4.	Correlación de Pearson	60
4.2.	Análisis de la serie de tiempo	61
4.2.1.	Análisis de la tendencia	61
4.2.2.	Análisis de estacionalidad	62
4.3.	Modelo de Winters	66
4.4.	Diseño de red neuronal artificial para el pronóstico del fenómeno El Niño	68
4.4.1.	Diseño de red neuronales para el pronóstico de variables explicativas; primera fase.	68
4.4.2.	Estructura de la RNA seleccionadas y resultados durante su ejecución	74
4.4.3.	Diseño de la red neuronal, segunda fase	89
4.4.4.	Pronóstico Fenómeno El Niño	99
4.5.	Análisis y comparación de resultados de los modelos	100
4.5.1.	Contraste de resultados	100



4.5.2. Análisis del pronóstico	102
CONCLUSIONES	105
RECOMENDACIONES	107
BIBLIOGRAFIA	108
ANEXOS	112

## ÍNDICE DE CUADROS

Cuadro 2.1: Daños físicos por sectores fenómeno El Niño 1982 – 1983	11
Cuadro 2.2: Daños totales causados por el fenómeno El Niño 1997-1998 por sectores económicos (millones de dólares)	13
Cuadro 3.1: Análisis de varianza bifactorial	41
Cuadro 3.2: Prueba de comparación de medias de Duncan bifactorial	41
Cuadro 3.3: Análisis de varianza trifactorial	42
Cuadro 3.4: Análisis de Duncan trifactorial	43
Cuadro 3.5: Variable dependiente	44
Cuadro 3.6: Variables independientes	45
Cuadro 4.1: Características principales de precipitaciones	48
Cuadro 4.2: Características principales de tsm niño 1+2	51
Cuadro 4.3: Características principales de tsm en zona niño 3	52
Cuadro 4.4: Características principales de tsm en zona niño 4	54
Cuadro 4.5: Características principales de la tsm en zona niño 3.4	56
Cuadro 4.6: Características principales de velocidad de vientos	58
Cuadro 4.7: Correlaciones de Pearson para las variables del modelo	60
Cuadro 4.8: Índices estacionales – análisis de estacionalidad con tendencia	63
Cuadro 4.9: Índices estacionales – análisis de estacionalidad sin tendencia	64
Cuadro 4.10: Pronóstico de precipitaciones enero – junio 2016 con método de Winters	67
Cuadro 4.11: Análisis de Duncan a un nivel de significancia de 0.05 y 27 grados de libertad del cuadrado medio del error, de tsm Niño 1+2	72
Cuadro 4.12: Análisis de Duncan a un nivel de significancia de 0.05, y 27 grados de libertad del cuadrado medio del error, velocidad de vientos	73
Cuadro 4.13: Pronóstico enero –junio 2016 de tsm niño 1+2	77
Cuadro 4.14: Pronóstico enero – junio 2016 de tsm niño 3	80
Cuadro 4.15: Pronóstico enero – junio 2016 de tsm niño 4	83
Cuadro 4.16: Pronóstico enero – junio 2016 de tsm niño 3.4	86
Cuadro 4.17: Pronóstico enero – junio 2016 de velocidad de los vientos alisios	89
Cuadro 4.18: Evaluación del error cuadrático medio de la rna para precipitaciones	91
Cuadro 4.19: Análisis de varianza para tsm Niño 1+2	92
Cuadro 4.20: Análisis de Duncan a un nivel de significancia de 0.05 y 81 grados de libertad del cuadrado medio del error, de precipitaciones	94

<b>Cuadro 4.21: Pronóstico enero – junio 2016 de las precipitaciones</b>	<b>100</b>
<b>Cuadro 4.22: Comparativo de error absoluto, ECM, RECM y MAPE de los modelos de precipitaciones</b>	<b>102</b>
<b>Cuadro 4.23: Comparativo de ECM, RECM y MAPE del pronóstico de los modelos</b>	<b>103</b>

## ÍNDICE DE FIGURAS

Figura 2.1: Condiciones normales y El Niño	9
Figura 2.2: Regiones El Niño en el Océano Pacífico	10
Figura 2.3: Evolución de precipitaciones durante el fenómeno El Niño 1982-1983	11
Figura 2.4: Evolución de precipitaciones durante el fenómeno El Niño 1997-1998	13
Figura 2.5: Estructura de la neurona	24
Figura 2.6: Ejemplo de red neuronal completamente conectada	28
Figura 2.7: Ejemplo de red neuronal con dos capas de entradas y una capa de salida	29
Figura 2.8: Red neuronal monocapa	32
Figura 2.9: Red neuronal multicapa	33
Figura 4.1: Análisis de precipitaciones en Piura 1979 – 2015	48
Figura 4.2: Diagrama de precipitaciones promedio mensuales	49
Figura 4.3: TSM zona Niño 1+2 entre 1979 – 2015	50
Figura 4.4: Diagrama de tsm en zona niño 1+2 promedio mensuales	51
Figura 4.5: TSM zona Niño 3 entre 1979 – 2015	52
Figura 4.6: Diagrama de tsm en zona niño 3 promedio mensuales	53
Figura 4.7: TSM zona Niño 4 entre 1979 – 2015	54
Figura 4.8: Diagrama de tsm en zona niño 4 promedio mensuales	55
Figura 4.9: TSM zona Niño 3.4 entre 1979 – 2015	56
Figura 4.10: Diagrama de tsm en zona niño 3.4 promedio mensuales	57
Figura 4.11: Velocidad de vientos alisios entre 1979 – 2015	58
Figura 4.12: Diagrama de velocidad de vientos alisios promedio mensuales	59
Figura 4.13: Gráfica de análisis de tendencia de precipitaciones en Piura 1979 – 2015	62
Figura 4.14: Gráfica de análisis de estacionalidad con tendencia	63
Figura 4.15: Gráfica de análisis de estacionalidad sin tendencia	65
Figura 4.16: Gráfica del modelo de Winters para precipitaciones	66
Figura 4.17: Entrenamiento de rna para tsm en niño 1+2	75
Figura 4.18: Aprendizaje de rna para temperatura tsm de niño 1+2	75
Figura 4.19: Ajuste del modelo de rna para tsm niño 1+2	76
Figura 4.20: Entrenamiento de rna para tsm niño 3	78
Figura 4.21: Aprendizaje de rna para tsm niño 3	78
Figura 4.22: Ajuste del modelo de rna para tsm niño 3	79
Figura 4.23: Entrenamiento de rna para tsm niño 4	81
Figura 4.24: Aprendizaje de rna para tsm niño 4	81
Figura 4.25: Ajuste del modelo de rna para tsm niño 4	82

Figura 4.26: Entrenamiento de rna para tsm niño 3.4	84
Figura 4.27: Aprendizaje de rna para tsm niño 3.4	84
Figura 4.28: Ajuste del modelo de rna para tsm niño 3.4	85
Figura 4.29: Entrenamiento de rna para velocidad de vientos alisios	87
Figura 4.30: Aprendizaje de rna para velocidad de vientos alisios	87
Figura 4.31: Ajuste del modelo de rna para velocidad de vientos alisios	88
Figura 4.32: Topología rna 5-10-14-1	96
Figura 4.33: Red neuronal	96
Figura 4.34: Entrenamiento de rna para precipitaciones	97
Figura 4.35: Aprendizaje de rna para precipitaciones	98
Figura 4.36: Ajuste del modelo de rna para precipitaciones	99
Figura 4.37: Comparativo de los valores reales de precipitaciones y los obtenidos con Winters	101
Figura 4.38: Comparativo de los valores reales de precipitaciones y los obtenidos con rna	101
Figura 4.39: Ampliación de gráfica comparativa precipitaciones reales - pronóstico rna	102
Figura 4.40: Gráfica de valores de pronóstico de precipitaciones (mm) para meses enero – junio 2016	103

## RESUMEN

El objetivo es construir una red neuronal que busque modelar el pronóstico del Fenómeno El Niño en Piura. En ella se han utilizado datos históricos tomados mensualmente de la temperatura superficial del mar en las 4 zonas denominadas El Niño y la velocidad de vientos alisios. La investigación se inicia con un análisis estadístico de las variables meteorológicas y con el estudio de la relación que tienen entre ellas. Luego se analizan los componentes de tendencia y estacionalidad de la serie de tiempo de las precipitaciones para ver el comportamiento de la variable y al mismo tiempo se implementa el modelo matemático de Winters. El diseño de la red neuronal artificial que modele el comportamiento del fenómeno El Niño se hace en dos etapas, la primera en la que se crean redes neuronales para cada variable independiente como una serie de tiempo y una segunda etapa en la que se construye la red neuronal en la cual ingresan los valores pronosticados de las redes neuronales de series de tiempo para realizar el pronóstico de las precipitaciones. La red que mejor ha modelado el problema, fue aquella que está compuesta por 10 neuronas en la primera capa oculta, 14 en la segunda capa oculta y 250 épocas. Haciendo una comparación entre el método de Winters y las redes neuronales artificiales, comprobamos que la metodología que mejor se ajustó en el pronóstico de las precipitaciones de Piura, fue la de redes neuronales artificiales, la cual obtuvo un error cuadrático medio de 0.0011 y un MAPE de 2.21% frente a los obtenidos con el método de Winter, con un error cuadrático medio de 0.0070 y un MAPE de 6.2585%.

Palabras Clave: redes neuronales artificiales, fenómeno El Niño, pronósticos, programación, arquitectura de las redes, procesamiento automático, inteligencia artificial, modelo predictivo.

## **ABSTRACT**

The objective is to build a neural network model that seeks forecast El Niño in Piura. It has been used historical data about monthly sea surface temperature in the 4 areas known as El Niño and speed of trade winds. The investigation begins with a statistical analysis of meteorological variables and the study of the relationship they have between them. the components of trend and seasonality of the time series of rainfall to see the behavior of the variable while the mathematical model is implemented Winters are then analyzed. The design of artificial neural network that models the behavior of El Niño is done in two stages, the first in which neural networks for each independent variable as a time series and a second stage in which the network is built are created neuronal in which enter the predicted values of neural networks for time series forecasting precipitation. The network has better modeling the problem was that it consists of 10 neurons in the first hidden layer, 14 in the second hidden layer and 250 times. Making a comparison between the method of Winters and artificial neural networks, we found that the methodology that best fit in the forecast rainfall of Piura, was the artificial neural network, which obtained a mean square error of 0.0011 and MAPE of 2.21% compared to those obtained with the method of Winter, with a mean square error of 0.0070 and MAPE of 6.2585%.

**Key words:** artificial neural networks, phenomenon El Niño, forecasts, programming, network architecture, automatic processing, artificial intelligence.

# Capítulo I: INTRODUCCIÓN

## 1.1. Planteamiento del problema

El Fenómeno El Niño es una fluctuación climática que ocurre en el océano pacífico, como consecuencia de un proceso de interacción del sistema océano-atmósfera a escala global, este fenómeno se considera como un evento aperiódico, por lo que este sucede hasta en cierta forma de manera sorpresiva; las diferentes facetas que presenta varían según las modalidades de interacción del océano y la atmósfera, así como sus ubicaciones.

Para el caso particular de Perú, durante el desarrollo del Fenómeno El Niño, dependiendo de su intensidad y temporalidad, los comportamientos de las condiciones meteorológicas en territorio nacional se alteran, provocando anomalías en el comportamiento de lluvias y temperaturas de aire (SENAMHI, 2014).

En la región Piura, durante los eventos extraordinarios El Niño que tuvieron lugar en los años 1982-1983 y 1997-1998, se observaron, mayormente impactos negativos en sus recursos agrícolas, marinos, mineros y de hidrocarburos, así como daños considerables y destrucción de vías de transporte, infraestructuras y viviendas, pérdidas humanas por huacos, enfermedades virales y hambre.

Durante muchos años, se han desarrollado muchos trabajos de investigación con la finalidad de encontrar un método para descubrir una relación que pueda predecir con certeza su presencia con anticipación, sin embargo, los resultados no han sido favorables.

Por lo tanto, la investigación que se propone, trata de utilizar la técnica de Redes Neuronales Artificiales (RNA), como una herramienta para obtener un modelo de pronóstico que cuente con un alto nivel de confiabilidad ya que estas están diseñadas para que tomen las mejores decisiones especialmente cuando el problema presenta comportamientos erráticos o completamente aleatorios.

La pregunta principal de la investigación es: ¿Será posible diseñar una arquitectura de red neuronal artificial que permita modelar las precipitaciones causadas por el Fenómeno El Niño con seis meses de anticipación?



## **1.2. Objetivos**

### **1.2.1. Objetivo general**

Modelar el pronóstico para seis meses del Fenómeno El Niño en Piura mediante la aplicación de Redes Neuronales Artificiales.

### **1.2.2. Objetivos específicos**

- Determinar la relación que tiene la presencia de aguas cálidas en las zonas clasificadas como Niño 1+2, Niño 3, Niño 3.4 y Niño 4 en la formación del Fenómeno El Niño.
- Determinar la relación que tiene la velocidad los vientos alisios en la formación del Fenómeno El Niño.
- Analizar la etapa de aprendizaje de la red neuronal artificial.
- Diseñar pronósticos del Fenómeno El Niño mediante el modelo matemático de Winter; y comparar sus resultados con los obtenidos en la red neuronal artificial, para determinar qué metodología ofrece el mejor resultado de predicción.

## **1.3. Justificación, importancia y beneficiarios**

### **1.3.1. Justificación**

Con frecuencia los fenómenos naturales destruyen los esfuerzos y las inversiones de muchos años, esto ha llevado a que gran parte de los científicos y especialistas de varias disciplinas, trabajen en conjunto para estudiar el origen y desarrollo de estos fenómenos con el objetivo de tomar las medidas adecuadas.

La presencia del fenómeno El Niño en nuestra región, ha significado una alta tasa de mortalidad, damnificados, pérdidas de cultivos, desaparición de especies marinas y daños en la economía. Este fenómeno tiene como principales características su aperiodicidad y la variación de su intensidad, lo que ha hecho que los métodos utilizados actualmente para pronosticar este fenómeno resulten ineficientes y sea muy tedioso su estudio, en consecuencia, su pronóstico.

Con el desarrollo de esta investigación se busca monitorear la presencia del Fenómeno El Niño y su intensidad en Piura. Adicionalmente se pretende que el siguiente trabajo sirva como aporte al campo de las redes neuronales, pues se desea dar a conocer sus ventajas, efectividad y aplicaciones.

### **1.3.2. Importancia**

El Perú, es uno de los lugares que constantemente ha sufrido las consecuencias devastadoras del Fenómeno El Niño. Por lo tanto, estudiar dicho fenómeno en nuestro país es de vital importancia. Conocedores de dicho problema, se pretende buscar un modelo mediante Redes Neuronales Artificiales, que funcione como una herramienta de alta confiabilidad que permita anticipar la presencia futura de dicho fenómeno en Piura.

La importancia principalmente se estima en términos de prevención y concientización hacia la población vulnerable. De esta manera permitirá tomar las medidas necesarias con el fin de mitigar los efectos y educar a la población acerca de cómo prepararse para la llegada de dicho fenómeno, evitando así, pérdidas en la industria pesquera, agrícola y turística principalmente, problemas de desabastecimiento energético, racionamiento de agua y alimentos; y en términos generales contrarrestar la disminución del crecimiento económico del país.

### **1.3.3. Beneficiarios**

La Investigación buscará dar a conocer un pronóstico sobre la presencia del Fenómeno El Niño en Piura, por lo tanto, serán los beneficiarios:

- La población que habita en zonas de alto riesgo, dado que tendrán un tiempo prudente para poder hacer las evacuaciones correspondientes.
- Los agricultores, ya que podrán tomar las medidas de prevención frente a los impactos del fenómeno El Niño, como son proliferación de plagas y enfermedades, suelos afectados por lodos y sedimentos, etc.
- Las Industrias, pues tendrán la oportunidad de abastecerse de materias primas y de rediseñar sus programas de producción para permanecer en el mercado aún en tiempos de escasez.

- Las autoridades, debido a que son los responsables de crear los programas de prevención, campañas de sensibilización y jornadas de evacuación correspondiente ante la presencia del fenómeno El Niño. Además, permitirá una mejor planificación y ejecución de los recursos económicos del país.
- La comunidad estudiantil, como material de consulta de aplicaciones de redes neuronales artificiales.

#### **1.4. Hipótesis: general y específicas**

##### **1.4.1. Hipótesis general**

Con la Aplicación de las Redes Neuronales Artificiales se podrá modelar el pronóstico de las precipitaciones causadas por el Fenómeno El Niño con una proyección de seis meses.

##### **1.4.2. Hipótesis específicas**

- El aumento prolongado de la temperatura superficial del mar en las zonas clasificadas como Niño 1+2, Niño 3, Niño 3.4 y Niño 4 inciden significativamente en la formación del Fenómeno El Niño con repercusiones directas en Piura.
- Las anomalías de la velocidad de los vientos alisios tienen repercusiones directas en la formación del Fenómeno El Niño.
- El estudio y análisis del aprendizaje de la red neuronal artificial permitirá obtener una configuración adecuada de la red que produzca las salidas deseadas.
- Las metodologías de redes neuronales artificiales y el método de Winters modelan adecuadamente el pronóstico de seis meses de las precipitaciones provocadas por el fenómeno El Niño.

## **Capítulo II: MARCO TEÓRICO**

### **2.1. Ubicación y descripción geográfica de Piura**

Piura es un departamento del Perú situado al extremo noroeste del país. Esta circunscripción colinda al oeste con el Océano Pacífico y limita con el departamento de Lambayeque al sur, con Cajamarca al este y Tumbes por el norte, así como con territorio ecuatoriano por el noreste. Comprende una dilatada planicie en su mayor extensión —Costa— y una región montañosa menos extensa en la zona oriental del departamento —Sierra—. Desde la zona montañosa discurren los ríos Piura y Chira, que irrigan las excepcionales zonas cultivadas de la planicie costera, donde se extiende el desierto peruano y el bosque seco ecuatorial. (Sánchez, 2014).

Según la Oficina de Gestión de la Información y Estadística, en el año 2015 Piura contaba con una población de 1'829,496 habitantes que representan el 5,93% de la población nacional, siendo la tercera región más poblada del país.

El departamento de Piura es un importante punto de desarrollo nacional, ya que centra su economía en la agricultura, pesca, hidrocarburos y el comercio.

Los productos agropecuarios son producidos mayormente en los valles formados por los ríos Chira y Piura, cuya área cultivable ha sido aumentada gracias a diversas obras de irrigación. En la serranía piurana, los valles interandinos producen alimentos que mayormente son destinados al autoconsumo.

El departamento de Piura produce árboles de algarrobo y se cultiva arroz, maíz amarillo, choclo, café, plátano, coco de pipa, limón, frijol, trigo, cebada, soya, papa, yuca, mango y otros frutales.

Igualmente es su litoral se encuentra varios yacimientos petroleros, sobre todo frente a las costas de Talara; en esta ciudad se encuentra una de las principales refinerías del país, la cual abastece al norte peruano e incluso a la ciudad de Lima.

La producción pesquera del departamento se destina principalmente a la harina de pescado y el 30% del pescado que es para consumo humano en todo el Perú desembarca por las numerosas caletas piuranas, y existe numerosos criaderos de peces tropicales.

### **2.1.1. Clima**

Debido a su proximidad con la línea ecuatorial, la costa de Piura tiene un clima cálido durante todo el año. La temperatura promedio es de 26 °C. El clima costero presenta características de clima tropical en zona yunga y de sabana tropical a nivel del mar. Este clima se le conoce también por seco tropical o bosque seco ecuatorial. Es un clima parecido al de la sabana tropical. La temperatura máxima puede alcanzar los 40 °C y la mínima los 15 °C. En la zona costera sur del departamento, colindando con el Departamento de Lambayeque, existe un clima semi desértico. La sierra piurana tiene un clima húmedo subtropical y templado con un promedio anual de 15 °C. (Flores, 2010).

### **2.1.2. Topología del suelo**

El departamento de Piura, presenta una topología variada y poco accidentada en la costa. En esta región la línea litoral se aleja ostensiblemente de la Cordillera de los Andes, quedando entre ambas una gran planicie, de aproximadamente 200 Km de ancho, comprende el Desierto de Sechura, el más extenso del Perú y el Tablazo de Piura; otros rasgos morfológicos son las dunas, los médanos, la depresión de Bayovar, las terrazas fluviales formadas por los ríos Chira y Piura. El relieve de la zona andina ocupada principalmente por las provincias de Ayabaca y Huancabamba es accidentado; determinada funcionalmente por la presencia de la sub-ramal externo de la Cordillera Occidental, que llega a un máximo de 3700 msnm. (Facho, 2012).

## **2.2. Fenómeno El Niño**

El Fenómeno de “El Niño” es un evento natural de variabilidad climática en el que se interrelacionan el océano y la atmosfera en la región tropical del Océano Pacífico. Este término se hizo conocido a partir de los años ochenta, cuando la comunidad científica demostró que había una interacción entre el océano y la atmosfera que lo explicaba. (SENAMHI, 2014).

Cabe resaltar que la presente investigación, tiene como objeto de estudio al Fenómeno El Niño que es de ocurrencia erráticamente cíclico y no a la Corriente El Niño cuya presencia es anual.

Se sabe que los efectos de este fenómeno involucran áreas en continentes como Asia, Europa, Oceanía y principalmente América ya que son afectadas de forma directa las costas peruanas y ecuatorianas con copiosas precipitaciones que traen consigo desastres naturales, plagas, hambruna entre otros.

### **2.2.1. ¿Cómo se produce?**

Según el Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres (2012) en su publicación Escenarios de Riesgos Ante la Probabilidad de Ocurrencia del Fenómeno El Niño, indica que el proceso de formación del presente fenómeno, sigue la siguiente secuencia de eventos:

Los vientos alisios (del sureste en el hemisferio sur y del noreste en el hemisferio norte), que soplan sobre el Pacífico tropical, convergen en el oeste del mismo (norte de Australia y sureste de Asia) cargados de humedad en una zona donde la superficie del mar está relativamente caliente (temperaturas por encima de 28°C), lo que provoca que se dé en esa zona una intensa convección (zona de lluvias).

Los vientos Alisios empujan a las corrientes oceánicas superficiales que fluyen hacia el Oeste y provocan un afloramiento de aguas profundas cerca de la costa este del Pacífico. Como resultado, el nivel del mar está como promedio unos 40 cm más altos en el oeste y la termoclina (superficie por debajo de la cual el agua del mar se considera a una temperatura constante) está en esa zona a unos 200 m de profundidad, mientras que en el este está a unos 50 m.

Cuando comienza una situación de El Niño los vientos alisios se debilitan, cesa el afloramiento de aguas profundas, las temperaturas del agua del mar empiezan a subir en el este del Pacífico tropical y aparecen las primeras anomalías positivas (temperaturas por encima de la media climatológica). Por otra parte, se da una advección de aguas cálidas desde el Oeste hacia el Este.

Como consecuencia, la zona convectiva del oeste del Pacífico empieza a trasladarse hacia el este y los vientos del oeste a extenderse hacia el Pacífico tropical central.

### **2.2.2. Corriente El Niño**

Comúnmente la población tiende a confundir los conceptos de Corriente El Niño y Fenómeno El Niño sin embargo estos no son lo mismo. La Corriente del Niño es una corriente marina de aguas cálidas que se presenta de forma periódica y normal que sucede cada año durante los meses de diciembre a abril; proviene del norte de la cuenca de Panamá y bajan por las costas de Sudamérica, este evento marca un claro cambio de estación en las costas de Ecuador y norte del Perú. Y el Fenómeno El Niño es un evento de magnitudes globales y de ocurrencia errática.

### **2.2.3. Condiciones normales y condiciones El Niño**


Según la NOAA (Administración Nacional para el Océano y la Atmósfera de los Estados Unidos de Norteamérica. Por sus siglas en inglés: *National Oceanic and Atmospheric Administration*), el comportamiento del océano y de la atmósfera en condiciones normales y condiciones El Niño (figura 2.1) es el siguiente:

Las condiciones normales se presentan cuando en la región occidental del Océano Pacífico Ecuatorial existe una masa de agua caliente, las corrientes atmosféricas desplazan ligeramente el volumen de agua del océano hasta la costa este.

En el Pacífico occidental el nivel del mar es más alto que en la región oriental, por algunos centímetros debido a que los fuertes vientos alisios soplan de oriente a occidente. La gran masa de agua cálida calienta la atmósfera sobre ella, haciendo que el aire se eleve y produzca nubes que generan lluvia.

Durante las condiciones El Niño, existen alteraciones importantes en las corrientes atmosféricas provocando que la circulación de los vientos alisios disminuyan su intensidad en su dirección o incluso invirtiéndose. Esto permite que la masa de agua cálida del oeste se mueva hacia el este, incrementando la temperatura

superficial del océano y se produce un descenso de la termoclina que provoca importantes impactos sobre la vida marina y en clima local.



**Figura 2.1: Condiciones normales y condiciones El Niño**  
Fuente: Recuperado de Fenómeno El Niño. [www.elclima.com.mx](http://www.elclima.com.mx)

#### 2.2.4. Regiones El Niño

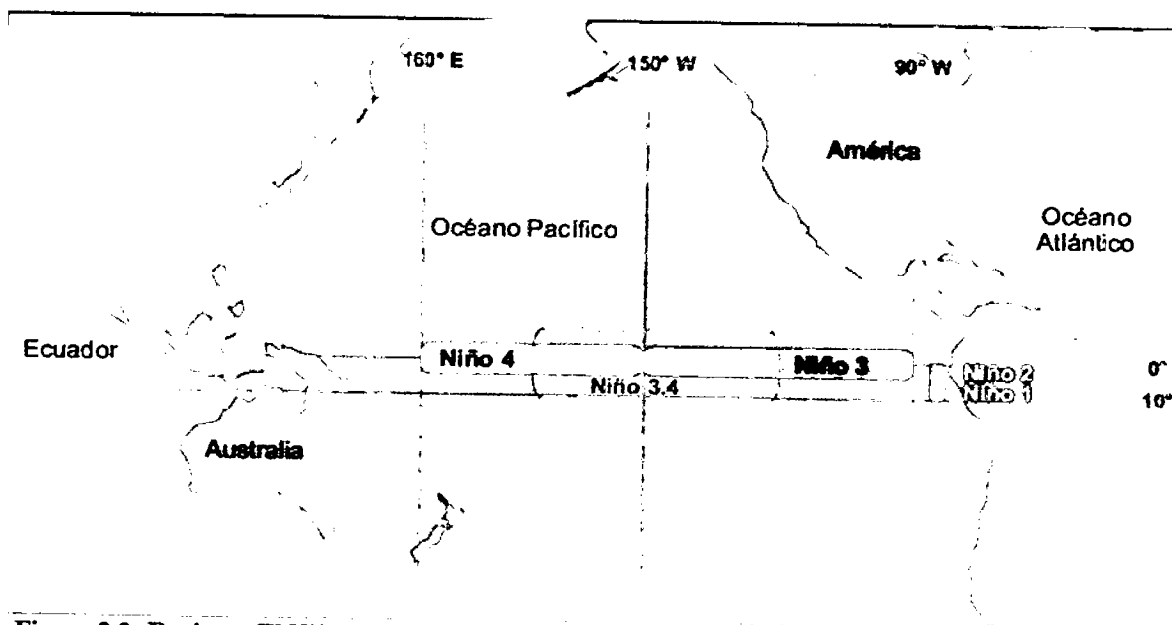
Según Instituto Oceanográfico de la Armada (2011), Para una mayor comprensión de cómo se desarrollan los eventos El Niño del ciclo ENOS a lo largo del Océano Pacífico Ecuatorial, se han definido cuatro regiones de acción. De Oeste a Este estas regiones son: Regiones Niño 4, Niño 3, Niño 3.4 y Región Niño 1+2.

Las regiones Niño 4 y 3 se encuentran ubicadas en el lado occidental del Pacífico, en las coordenadas (5°N - 5°S) (160°E - 150°W) y (5°N - 5°S) (150°W - 90°W) respectivamente y se caracterizan por presentar las máximas anomalías de temperatura superficial del mar (tsm).

La región Niño 3.4 es una subregión comprendida entre las regiones Niño 4 y 3 ubicada en las coordenadas (5°N - 5°S) (170 - 120°W) y representa un buen indicador de la correlación entre la temperatura superficial del mar y el índice de Oscilación del Sur.

La región Niño 1+2 incluye las costas de Perú y Ecuador incluidas las Islas Galápagos, ubicada en las coordenadas (0 - 10°S) (90°W - 80°W), esta región representa un indicador de los cambios inducidos por El Niño en los patrones de variabilidad de la costa del Pacífico de América del Sur.





**Figura 2.2: Regiones El Niño en el Océano Pacífico**  
**Fuente: NOAA**

### **2.2.5. Fenómeno El Niño de 1982 – 1983**

El fenómeno El Niño ocurrido en este periodo ha sido considerado como un “Mega-niño” por el poder de destrucción con el que se presentó en Perú, este evento tuvo características particulares como la presencia de copiosas precipitaciones en el norte y fuertes sequías en el sur.

Los daños físicos ocasionados en la región Piura, se estiman en 258.2 millones de dólares (ver cuadro 2.1), considerada así, como la región más afectada del país con un 80% del daño total registrado en el norte del Perú (323.8 millones de dólares), dichos daños se ubican principalmente en los sectores de hidrocarburos, transporte y comunicaciones, agricultura y vivienda (Ferradas, 2000).

Cuadro 2.1: Daños físicos por sectores fenómeno El Niño 1982 - 1983

Consolidado de daños físicos en la infraestructura por lluvias e inundaciones a junio de 1983 (Millones de Dólares)				
Sector	Piura	Lambayeque	La Libertad	Total
Agricultura	35.7	7.8	21.0	64.6
Pesquería	3.6	-	-	3.6
Industria	-	-	-	0.0
Energía	5.4	4.6	0.0	10.0
Hidrocarburos	105.9	-	-	105.9
Transporte y Comunicaciones	74.4	22.3	5.8	102.5
Turismo	0.0	-	-	0.0
Salud	0.6	0.2	0.1	0.9
Educación	2.8	0.4	0.3	3.6
Vivienda	29.5	2.3	0.6	32.4
Interior	0.3	-	-	0.3
<b>Total</b>	<b>258.2</b>	<b>37.7</b>	<b>27.9</b>	<b>323.8</b>

Fuente: Galarza, E. y Kamiche, J. (2012).

Los efectos en la economía nacional se vieron reflejados en la disminución del PBI en 12.3% y en un incremento promedio del quinquenio posterior de 0%.

A continuación, se presenta una gráfica de las precipitaciones en Piura con la finalidad de conocer su evolución a través del tiempo (enero 1982 – diciembre 1983) durante el Fenómeno El Niño.

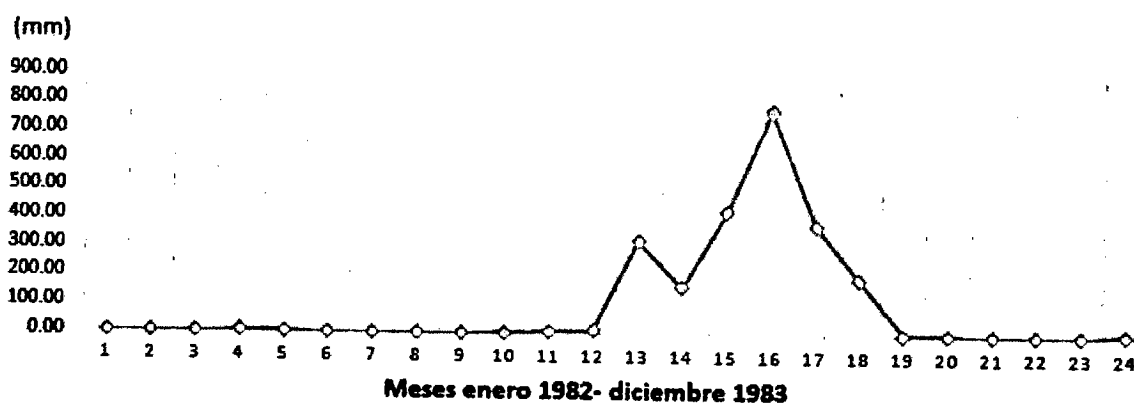


Figura 2.3: Evolución de precipitaciones durante el fenómeno El Niño 1982-1983  
Elaboración propia

Como podemos observar en la figura 2.3, el régimen de lluvias en el periodo 1982-1983 se inicia en el mes de diciembre de 1982 con precipitaciones que alcanzan los 10.4 mm, luego se muestra un gran incremento en el mes de enero de 1983 con precipitaciones de 324.5 mm y en los siguientes meses podemos ver su evolución, en

el mes de febrero presentó 161 mm, el mes de marzo, 427 mm y en el mes de abril se presentó el pico más alto registrado, 778 mm, el mes de mayo acumuló 379 mm, en el mes de junio se presentó un descenso llegando a 192 mm, y en el mes de julio regresa a la normalidad, 0.7 mm, como resultado en este periodo se registraron precipitaciones por un total de 2263 mm. Hasta la fecha, este es el periodo con el mayor impacto en Piura del que se tiene un registro detallado.

#### **2.2.6. Fenómeno El Niño de 1997 – 1998**

En el periodo comprendido entre los años 1997 y 1998, el Fenómeno El Niño reapareció con la misma intensidad que en el episodio del año 1983 afectando las costas del Pacífico en especial a Bolivia, Colombia, Ecuador, Venezuela y Perú.

Los mayores generadores de impactos en el territorio nacional fueron las lluvias torrenciales, deslizamientos, crecidas de ríos e inundaciones. En nuestro país, los departamentos más afectados fueron Piura, Lambayeque, Tumbes, Ica, La Libertad, así como Lima (Galarza, E. y Kamiche, J. 2012).

Los daños totales originados por el Fenómeno El Niño 1997-1998 ascendieron a 3.500 millones de dólares, que representan más del 4.5% del PBI de 1997 (ver cuadro 2.2.) Los sectores productivos (agropecuario, pesca, minería, industria y comercio) fueron los más afectados debido a que las inundaciones dañaron tanto la infraestructura como la producción agropecuaria; asimismo, los cambios en la temperatura del mar afectaron la pesca y se dieron pérdidas en la producción del sector industrial y comercial. También se presentaron daños en el transporte, especialmente carreteras, caminos y puentes (Corporación Andina de Fomento, 2000).

Cuadro 2.2: Daños totales causados por el fenómeno El Niño 1997-1998 por sectores económicos (millones de dólares)

Sector/Subsector	Daño Directo	Daño Indirecto	Daño Total
<b>Sector Sociales</b>	457	29	486
Vivienda	202	21	223
Educación	224	4	228
Salud	31	4	34
<b>Sector de Servicios</b>	778	177	955
Agua y saneamiento	63	8	71
electricidad	111	55	166
Transporte	604	114	718
<b>Sectores Productivos</b>	319	1307	1626
Agropecuario	163	449	612
Pesca	15	11	26
Minera	28	16	44
Industria	7	668	675
Comercio	106	163	269
Otros Daños	58	376	434
<b>Total Nacional</b>	1612	1890	3501
Gastos de prevención	0	219	219
Gastos de la emergencia	0	157	157

Fuente: Corporación Andina de Fomento (2000)

A continuación, se presenta una gráfica de las precipitaciones en Piura con la finalidad de conocer su evolución a través del tiempo (enero 1997 – diciembre 1998) durante el Fenómeno El Niño.




Figura 2.4: Evolución de precipitaciones durante el fenómeno El Niño 1997-1998  
Elaboración propia

Como se puede observar en la figura 2.4, el régimen de lluvias en el periodo 1997-1998 se inicia en el mes de diciembre de 1997 con precipitaciones intensas que alcanzan los 170.7 mm, luego se muestra un gran incremento alcanzando, en el mes

de enero de 1998, el pico más alto, con precipitaciones de 769.2 mm, en el mes de febrero presentó 501.8 mm, el mes de marzo, 479.9 mm, en el mes de abril se presentó, 90.9 mm y en el mes de mayo regresa a la normalidad, como resultado en este periodo se registraron precipitaciones por un total de 2020.9 mm.

### **2.3. Estudio de los modelos de pronósticos**

Podemos decir que, hacer un pronóstico es utilizar información de un evento pasado para poder conocer su comportamiento en el futuro. Suelen ser muy utilizados para anticiparse al comportamiento de la demanda, sin embargo, presentan una amplia gama de sucesos, como por ejemplo de la estimación de la materia prima para la elaboración de un producto o sus costos de producción, entre otros.

Pronosticar es la ciencia de anticiparse al comportamiento futuro de un evento y esto implica el manejo de información histórica para poder realizar una proyección. Existen muchas técnicas de pronósticos, pero no existe un único modelo para un determinado problema, así pues, lo que puede ser una solución muy asertiva para una empresa, para otra puede ser un completo desastre. Son muy raros los casos perfectos.

#### **2.3.1. Enfoques para la elaboración de pronósticos**

Con frecuencia dos son los métodos más utilizados en la predicción, el método de extrapolación y los métodos de predicción causal para hacer pronósticos.

Los métodos de extrapolación se utilizan para pronosticar los valores futuros de series de tiempo a partir de valores anteriores de una serie temporal; estos métodos suponen que los patrones anteriores y las tendencias en los períodos futuros continuarán, por lo tanto la información anterior relacionada con la serie temporal se utiliza para generar los valores futuros de la serie temporal, estos métodos no consideran el hecho de qué “ocasionó” los datos anteriores; simplemente se asume que las tendencias y los patrones anteriores continuarán en el futuro.

Los métodos de pronóstico causales pretenden pronosticar los valores futuros de una variable (llamada variable dependiente) con la ayuda de la información anterior, a fin de estimar la relación entre la variable dependiente y una o más variables independientes. Por ejemplo, una compañía puede tratar de pronosticar las

ventas futuras por mes de un producto a partir de los datos anteriores, para determinar cuál es la relación entre las ventas de producto y las variables independientes, como precio, publicidad y el mes del año.

### **2.3.2. Pronósticos basados en series de tiempo**

Por series de tiempo nos referimos a datos estadísticos que se recopilan, observan o registran en intervalos de tiempos regulares (diario, semanal, semestral, anual, entre otros). El término series de tiempo se aplica por ejemplo a datos registrados en forma periódica que muestran, las ventas anuales totales de almacenes, el valor trimestral total de contratos otorgados, el valor trimestral del PBI, etc.

### **2.3.3. Componentes de una serie de tiempo**

El primer paso para realizar un análisis de serie de tiempo es gráficarla, ya que nos permite identificar las componentes de tendencia, estacionalidad y variaciones irregulares. Los modelos clásicos de las series de tiempo, son expresados como la suma o el producto de las tres componentes (Arellano, 2001).

- **Tendencia:** El cambio gradual de la serie de tiempo se conoce como tendencia. Este cambio o tendencia por lo general es el resultado de factores a largo plazo, como cambios en la población, características demográficas de la población, tecnología y preferencias de consumo. La tendencia puede ser creciente o decreciente, lineal o no. La tendencia es el componente de largo plazo que representa el crecimiento o el descenso en la serie de tiempo, durante un periodo extenso.
- **Variación estacional:** Mientras que el componente de tendencia de una serie de tiempo, se identifican mediante el análisis de los movimientos de datos históricos durante varios años, muchas series de tiempo muestran un patrón regular durante periodos de un año. Aunque por lo general consideramos que el movimiento estacional en una serie de tiempo ocurre en un año, el componente estacional también puede utilizarse para representar cualquier patrón que se repite con regularidad y tiene una duración menor a un año.

Matemáticamente, podemos decir que la serie representa variación estacional si existe un número  $s$  tal que  $x(t) = x(t + k \times s)$ , siendo  $k$  el número de periodos

estacionales que presenta la serie ( $k=12$  si las observaciones son mensuales,  $k=4$  si son trimestrales, etc);

#### 2.3.4. Modelos clásicos de series de tiempo

Existen tres modelos de series de tiempo, que generalmente se aceptan como buenas aproximaciones a las verdaderas, entre los componentes de los datos observados. Estos son:

- Aditivo: 
$$X(t) = T(t) + E(t) + A(t) \quad (2.1)$$

- Multiplicativo: 
$$X(t) = T(t) \cdot E(t) \cdot A(t) \quad (2.2)$$

- Mixto: 
$$X(t) = T(t) \cdot E(t) + A(t) \quad (2.3)$$

Dónde:

$X(t)$  = Serie observada en instante  $t$

$T(t)$  = Componente de tendencia

$E(t)$  = Componente estacional

$A(t)$  = Componente aleatoria (accidental)

Una suposición usual es que  $A(t)$  es un componente aleatorio o ruido blanco con media cero y varianza constante.

Un modelo aditivo (2.1), es adecuado, por ejemplo, cuando  $E(t)$  no depende de otras componentes, como  $T(t)$ , si por el contrario la estacionalidad varia con la tendencia, el modelo más adecuado es un modelo multiplicativo (2.2). Es claro que el modelo 2 puede ser transformado en aditivo, tomando logaritmos. El problema que se presenta, es modelar adecuadamente las componentes de la serie.

#### 2.3.5. Medición del error de pronóstico

El presente trabajo tiene como uno de sus objetivos la comparación de los pronósticos del Fenómeno El Niño a través de diferentes modelos de pronósticos para que puedan ser confiables en un periodo futuro.

Una de las medidas de comparación que se utilizan comúnmente para elegir el mejor modelo es el cálculo de los diferentes métodos de error. La mayoría de ellos implica el promediar alguna función de la diferencia entre el valor estimado y el valor observado.

En la presente investigación se utilizará cuatro tipos de error que se detallan a continuación:

- **Error porcentual absoluto medio (MAPE, Mean Absolute Percentage Error)**

Expresa la exactitud como un porcentaje del error. Como este número es un porcentaje, puede ser más fácil de entender que los otros estadísticos. La ecuación es:

$$\frac{\sum |(y_t - \hat{y}_t) / y_t|}{n} \times 100 \quad (2.4)$$

Donde  $y_t$  es igual al valor real,  $\hat{y}_t$  es igual al valor ajustado o pronosticado y  $n$  es igual al número de observaciones.

- **Desviación absoluta media (MAD, Mean Absolute Deviation)**

Expresa exactitud en las mismas unidades que los datos, lo cual ayuda a conceptualizar la cantidad de error. Los valores atípicos tienen menos efecto en MAD que en MSD. La ecuación es:

$$\frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n} \quad (2.5)$$

Donde  $y_t$  es igual al valor real,  $\hat{y}_t$  es igual al valor ajustado y  $n$  es igual al número de observaciones.

- **Desviación cuadrática media (ECM, MSD, Mean Squared Deviation)**

Una medida utilizada comúnmente de la exactitud de los valores ajustados de las series de tiempo. El MSE mide el promedio del cuadrado del "error", siendo el



error el valor en la que el estimador difiere de la cantidad a ser estimada. Los valores atípicos tienen mayor efecto en MSD que en MAD. La ecuación es:

$$\frac{\sum_{t=1}^n |y_t - \hat{y}_t|^2}{n} \quad (2.6)$$

Donde  $y_t$  es igual al valor real,  $\hat{y}_t$  es igual al valor del pronóstico y  $n$  es igual al número de pronósticos.

- **Raíz Desviación cuadrática media (RECM, RMSD, Mean Squared Deviation)**

Una medida utilizada con frecuencia para medir las diferencias entre los valores de la muestra predichos por un modelo y los valores realmente observados. La RMSD representa la desviación estándar de muestra de las diferencias entre los valores predichos y los valores observados

$$\sqrt{ECM} \quad (2.7)$$

Donde ECM es el Error cuadrático medio.

### 2.3.6. Modelo de Winters

Los métodos de suavizamiento exponencial han sido utilizados con éxito a través de los años en muchos problemas de pronóstico. Fueron sugeridos en 1957 por C.C. Holt para su aplicación en series de tiempo sin tendencia ni estacionalidad. Posteriormente el mismo ofreció un procedimiento que manejara tendencias. Después Winters en 1965 generalizó el método para incluir estacionalidad.

Este método se aplica frecuentemente para el pronóstico de serie de tiempo. Calcula los estimados de tres componentes, el nivel, la tendencia y la estacionalidad. Estas ecuaciones dan una mayor ponderación a observaciones recientes y menos peso a las observaciones pasadas, las ponderaciones decrecen geométricamente a una tasa constante.

El método de Winters trabaja a través de constantes de suavización  $\alpha$ ,  $\gamma$  y  $\delta$  que tienen un valor comprendido entre 0 y 1, con ellas se determina el grado del nivel, tendencia y de estacionalidad respectivamente, este valor refleja cuanto influyen las

observaciones anteriores en el pronóstico, pero dicha influencia declina exponencialmente al volverse cada vez más antiguos los datos.

Para los valores iniciales calculados solo con los datos del comienzo de la serie existen diferentes posibilidades. Ninguna de ella se descarta por ser mejor que el resto, para este estudio se tomaran los siguientes valores:

$$A_0 = \bar{y}_1 \quad (2.8)$$

$$T_0 = 0 \quad (2.9)$$

$$S_{t-c} = \frac{y_t}{y_c} \quad (2.10)$$

Donde:

$t = 1, 2, \dots, c$

$c =$  frecuencia de la muestra

Las ecuaciones que emplea el modelo de Winter son:

$$A_t = \alpha \frac{Y_t}{S_{t-L}} + (1 - \alpha)(A_{t-1} + T_{t-1}) \quad (2.11)$$

$$T_t = \gamma(A_t - A_{t-1}) + (1 - \gamma)T_{t-1} \quad (2.12)$$

$$S_t = \delta \left( \frac{Y_t}{A_t} \right) + (1 - \delta)S_{t-L} \quad (2.13)$$

El pronóstico de  $p$  periodos en el futuro

$$\bar{Y}_{t+p} = (A_t + pT_t)S_{t-L+p} \quad (2.14)$$

Dónde:

$A_t =$  nuevo de nivel

$\alpha =$  constante de suavización

$Y_t =$  nuevo valor real de la serie en periodo  $t$

$\gamma$  = Constante de suavización de la estimación de la tendencia

$T_t$  = Estimación de la tendencia

$\delta$  = constante de suavización de la estimación de la estacionalidad

$S_t$  = estimación de la estacionalidad

$L$  = longitud de la estacionalidad o longitud del patrón que se repite en un periodo fijo, por ejemplo, si los datos son anuales,  $L$  será igual a 12.

$Y_{t+p}$  = pronóstico de  $p$  periodos futuros

Ejemplo:

Se muestran datos trimestrales comprendidos desde el año 2012 hasta 2015. Calcular el pronóstico de la serie de tiempo para los 4 trimestres siguientes, correspondientes al año 2016 utilizando el método de Winters, tomar el valor de las constantes de suavización  $\alpha=0.5$ ,  $\gamma=0.5$  y  $\delta=0.5$ :

t	y
1	10
2	14
3	8
4	25
5	16
6	22
7	14
8	35
9	15
10	27
11	18
12	40
13	28
14	40
15	25
16	65

Puesto que ya conocemos los valores de las constantes de suavización, podemos empezar realizando los cálculos de los valores iniciales de los índices estacionales, los cuales para este caso son cuatro, ya que los datos son trimestrales:

$$S_1 = \frac{10}{(10+14+8+25)/4} = 0.701754$$

$$S_2 = \frac{14}{(10+14+8+25)/4} = 0.982456$$

$$S_3 = \frac{8}{(10+14+8+25)/4} = 0.561404$$

$$S_4 = \frac{25}{(10+14+8+25)/4} = 1.754386$$

Posteriormente se calcula los valores iniciales de nivel y tendencia:

$$A_0 = \frac{10+14+8+25}{4} = 14.25$$

$$T_0 = 0$$

Luego, procedemos a realizar los cálculos correspondientes para cada dato de la serie:

$$A_5 = (0.5) \times \frac{16}{0.701754} + (1-0.5)(14.25+0) = 18.525$$

$$T_5 = 0.5 \times (18.525 - 14.25) + (1-0.5) \times 0 = 2.1375$$

$$S_5 = 0.5 \times \left( \frac{16}{18.525} \right) + (1-0.5) \times 0.701754 = 0.782726$$

Por lo tanto, el valor estimado será:

$$\hat{Y}_5 = (14.25 + (5-4) \times 0) \times 0.701754 = 10$$

En consecuencia, obtenemos la siguiente tabla:

$Q_t$	$t$	$y$	$A$	$T$	$S$	Predicción	Error Absoluto
2012 - Q1	1	10			0.7018		
2012 - Q2	2	14			0.9825		
2012 - Q3	3	8			0.5614		
2012 - Q4	4	25	14.2500	0.0000	1.7544		
2013 - Q1	5	16	18.5250	2.1375	0.7827	10.0000	6.0000
2013 - Q2	6	22	21.5277	2.5701	1.0022	20.3000	1.7000
2013 - Q3	7	14	24.5176	2.7800	0.5662	13.5286	0.4714
2013 - Q4	8	35	23.6238	0.9431	1.6180	47.8906	12.8906
2014 - Q1	9	15	21.8654	-0.4077	0.7344	19.2292	4.2292
2014 - Q2	10	27	24.1992	0.9631	1.0590	21.5049	5.4951
2014 - Q3	11	18	28.4763	2.6201	0.5992	14.2472	3.7528
2014 - Q4	12	40	27.9094	1.0266	1.5256	50.3131	10.3131
2015 - Q1	13	28	33.5319	3.3245	0.7847	21.2497	6.7503
2015 - Q2	14	40	37.3145	3.5536	1.0655	39.0298	0.9702
2015 - Q3	15	25	41.2967	3.7679	0.6023	24.4864	0.5136
2015 - Q4	16	65	43.8355	3.1533	1.5042	68.7501	3.7501
2016 - Q1	17					<b>35.3621</b>	
2016 - Q2	18					<b>50.0651</b>	
2016 - Q3	19					<b>28.2998</b>	
2016 - Q4	20					<b>70.6808</b>	

Finalmente, calculamos los errores:

$$ECM = \left[ \frac{(16-10)^2 + (22-20.3)^2 + \dots + (65-68.75)^2}{12} \right] = 36.22$$

$$RECM = \sqrt{36.22} = 6.018$$

$$MAPE = \left[ \frac{\left(\frac{16-10}{16}\right) + \left(\frac{22-20.3}{22}\right) + \dots + \left(\frac{65-68.75}{65}\right)}{12} \right] = 1.8172\%$$

## **2.4. Redes neuronales artificiales**

Con las Redes Neuronales Artificiales (RNA) se busca la solución de problemas complejos, no como una secuencia de pasos, sino como la evolución de unos sistemas de computación inspirados en el cerebro humano, y dotados por tanto de cierta inteligencia (Hilera y Martínez, 1995). Estos sistemas de computación son una combinación de elementos simples de proceso (neuronas) interconectados, que, operando de forma paralela en varios estilos, consiguen resolver problemas relacionados con el reconocimiento de formas o patrones, predicción, codificación, control y optimización, entre otras aplicaciones.

Quienes primero concibieron algunos fundamentos de la computación neuronal fueron Warren McCulloch y Walter Pitts. En 1957, Frank Rosenblatt comento el desarrollo del Perceptrón, la red neuronal más antigua.

Más adelante apareció el modelo ADALINE, desarrollado por Bernard Widrow y Marcial Hoff. Luego Stephen Grossberg realizó Avalancha en 1967, hasta 1982 el crecimiento se frenó, pero surgieron luego investigaciones sobre redes como la de Marvin Minsky y Seymour Papertm después James Anderson desarrollo el Asociador Lineal, en Japón Kunihiko Fukushima y Teuvo Kohonen que se centraron en las redes neuronales para el reconocimiento de patrones.

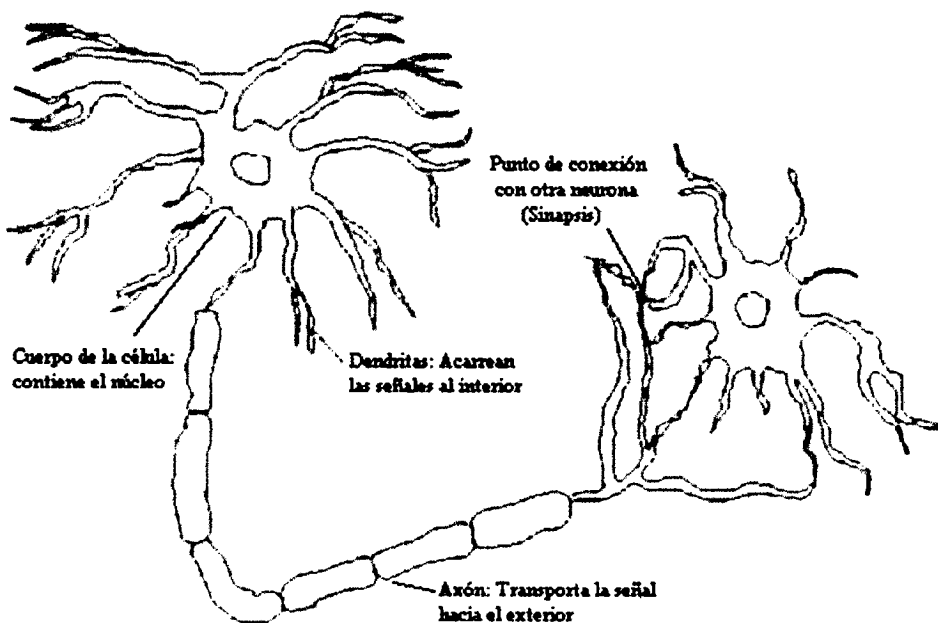
Debido a su constitución y a sus fundamentos, las RNA presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a casos nuevos, de abstraer característica esencial a partir de entradas que representan información irrelevante, etc. Esto hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas.

### **2.4.1.El modelo de la red neuronal**

La teoría de redes neuronales está inspirada en la estructura y funcionamiento de los sistemas nerviosos, donde la neurona es el elemento fundamental. En general, una neurona consta de un cuerpo celular más o menos esférico, de 5 a 10 micras de

diámetro, del que salen una rama principal, el axón y varias ramas cortas, llamadas dendritas. Una de las características de las neuronas es su capacidad de comunicarse.

En términos generales las dendritas y el cuerpo celular reciben señales de entrada; el cuerpo celular las combina e integra y emite señales de salida. El axón transmite dichas señales a los terminales axónicos, que distribuyen información o un nuevo conjunto de neuronas, se calcula que en el cerebro humano existen  $10^5$  conexiones. Las señales que se utilizan son de dos tipos: eléctrica y química. La señal generada por la neurona y transportada a lo largo del axón es un impulso eléctrico, mientras que la señal que se transmite entre los terminales axónicos de una neurona y las dendritas de la otra es el origen químico.



**Figura 2.5: Estructura de la neurona**  
**Fuente: Martínez (2008)**

Para establecer una similitud directa entre la actividad sináptica y la analogía con las redes neuronales artificiales podemos considerar: las señales que llegan a la sinapsis son las entradas a la neurona; estas son ponderadas a través de un parámetro, denominado peso asociado a la sinapsis correspondiente. Estas señales de entrada pueden excitar a la neurona (sinapsis con peso positivo) o inhibirla (peso negativo). El efecto es la suma de las entradas ponderadas. Si la suma es igual o mayor que el umbral de la neurona, entonces la neurona se activa (da salida). Esta es una situación

de todo o nada; cada neurona se activa o no se activa. La facilidad de transmisión de señales se altera mediante la actividad del sistema nervioso. Las sinapsis son susceptibles a la fatiga, deficiencia de oxígeno y la presencia de anestésicos, entre otros. Esta habilidad de ajustar señales es un mecanismo de aprendizaje.

Las redes neuronales artificiales (RNA) son modelos que intentan reproducir el comportamiento del cerebro. Como tal modelo, realiza una simplificación, averiguando cuales son los elementos relevantes del sistema, bien porque la cantidad de información de que se dispone es excesiva o bien porque es redundante. Una elección adecuada de sus características, más una estructura conveniente, es el procedimiento convencional utilizado para construir redes capaces de realizar determinada tarea. (Martínez, 2008).

#### **2.4.2. Caracterización de las redes neuronales**

La distribución de neuronas dentro de la red se realiza formando niveles o capas de un número determinado de neuronas cada una. Existen capas de entrada, de salida y ocultas. Cuando ninguna salida de las neuronas es entrada de neuronas del mismo nivel o de niveles precedentes, la red se describe como la propagación hacia adelante. Cuando las salidas pueden ser conectadas como entradas de neuronas de niveles previos o del mismo nivel, incluyéndose ellas mismas, la red es propagación hacia atrás.

Existen cuatro aspectos que caracterizan una red neuronal:

- a) **Autoorganización:** las redes neuronales usan su capacidad de aprendizaje adaptativo para organizar la información que reciben durante el aprendizaje y/o la operación. Una RNA puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje. Esta organización provoca la facultad de las redes neuronales de responder apropiadamente cuando se les presentan datos o situaciones a los que no habían sido expuestas anteriormente.
- b) **Tolerancia a Fallos:** Comparados con los sistemas computacionales tradicionales, los cuales pierden su funcionalidad en cuanto sufren un pequeño error de memoria, en las redes neuronales, si se produce un fallo en un pequeño número



de neuronas, aunque el comportamiento del sistema se ve influenciado, sin embargo, no sufre una caída repentina. La razón por la cual las redes neuronales son tolerables es que tienen su información distribuida en las conexiones entre neuronas, existiendo cierto grado de redundancia en ese tipo de almacenamiento, a diferencia de la mayoría de los ordenadores algorítmicos y sistemas de recuperación de datos que almacenan cada pieza de información en un estado único, localizado y direccionable.

- c) Operación en Tiempo Real: Los computadores neuronales pueden ser realizados en paralelo, y se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.
- d) Fácil inserción dentro de la tecnología existente: Debido a que una red puede ser rápidamente entrenada, comprobada, verificada y trasladada a una implementación de hardware de bajo costo, es fácil insertar RNA para aplicaciones específicas dentro de sistemas existentes (chips, por ejemplo). De esta manera, las redes neuronales se pueden utilizar para mejorar sistemas de forma incremental, y cada paso puede ser evaluado antes de acometer un desarrollo más amplio.

En cuanto a la topología, los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas. El aprendizaje es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el proceso de aprendizaje se reducen a la destrucción, modificación y creación de conexiones entre las neuronas, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero, una conexión se destruye cuando su peso pasa a ser cero. Se puede afirmar que el proceso de aprendizaje ha finalizado (la red ha aprendido) cuando los valores de los pesos permanecen estables.

Respecto al tipo de asociación entre las informaciones de entrada y salida, las RNA son sistemas que almacenan cierta información aprendida; esta información se registra de forma distribuida en los pesos asociados a las conexiones entre neuronas de entrada y salida. Por último, la representación de entrada y salida, es un gran

número de redes, tanto los datos de entrada como de salida son de naturaleza analógica, cuando esto ocurre, las funciones de activación de las neuronas serán también continuas, del tipo lineal o sigmoideal. Otras redes solo admiten valores discretos o binarios a su entrada, generando también unas respuestas en la salida de tipo binario. En este caso, las funciones de activación de las neuronas son de tipo escalón. Existe también un tipo de redes híbridas en las que las informaciones de entrada pueden ser valores continuos, aunque las salidas de la red son discretas.

### **2.4.3. Diseño y construcción de redes neuronales**

Un neurocomputador es básicamente un conjunto de procesadores conectados con cierta regularidad que operan concurrentemente. En la actualidad ya existen una serie de neurocomputadores comerciales destinados a la realización de redes neuronales. Por otro lado, la construcción de RNA puede llevarse a cabo por medio de uno o varios circuitos integrados específicos, para así poder obtener una estructura que se comporte lo más similar posible a como lo haría una red neuronal. Otra tecnología que podría ser apropiada en la implementación de las redes neuronales es la tecnología electroóptica, con la ventaja de utilizar la luz como medio de transporte de la información, permitiendo la transmisión, masiva de datos. (Rosa, 2013)

La construcción más simple e inmediata consiste en simular la red sobre un ordenador convencional mediante un software específico. Es un procedimiento rápido y económico, pero su mayor desventaja radica en el hecho de que intentan simular redes con un alto grado de paralelismo sobre máquinas que ejecuten secuencialmente las operaciones. Valores intrínsecos de las redes neuronales no pueden obtener de esta forma.

Otro método es la realización de redes neuronales a través de arquitecturas orientadas a la ejecución de procesos con un alto grado de paralelismo, tales como redes de transputers, arquitecturas sistólicas, etc. Este método es una optimización del anterior, ya que acelera el proceso, permitiendo una respuesta en tiempo real, pero el comportamiento real de la red sigue siendo simulado por una estructura ajena a la estructura intrínseca de una red neuronal.

Una tercera aproximación radicalmente distinta es la realización de redes neuronales mediante su implementación por uno o varios circuitos integrados específicos. Son los llamados chips neuronales. Las neuronas y conexiones se emulan con dispositivos específicos, de forma que la estructura del circuito integrado refleja la arquitectura de la red.

#### 2.4.4. Elementos básicos que componen una red neuronal

A continuación, se puede ver, la Figura 2.6, un esquema de una red neuronal:




Figura 2.6: Ejemplo de red neuronal completamente conectada  
Fuente: Jorge (2001)

Según Jorge (2001), la misma está constituida por neuronas interconectadas y arregladas en tres capas (esto último puede variar). Los datos ingresan por medio de la “Capa De Entrada”, pasan a través de la “Capa Oculta” y salen por la “Capa De Salida”. Cabe mencionar que la capa oculta puede estar constituida por varias capas.

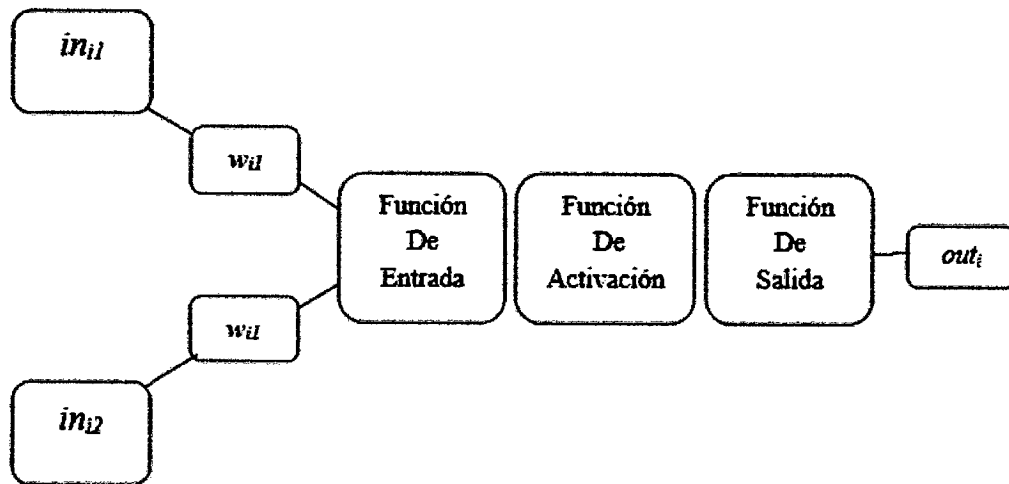
##### a. Función de Entrada (input function)

La neurona trata a muchos valores de entrada como si fueran uno solo; esto recibe el nombre de entrada global. Por lo tanto, ahora nos enfrentamos al problema de cómo se pueden combinar estas simples entradas ( $ini1$ ,  $ini2$ , ...) dentro de la entrada global,  $g_ni$ . Esto se logra a través de la función de entrada, la cual se calcula a partir del vector entrada. La función de entrada puede describirse como sigue:

$$\text{Input} = (in_{i1} \cdot w_{i1}) * (in_{i2} \cdot w_{i2}) * \dots (in_{in} \cdot w_{in})$$

Dónde: \* representa al operador apropiado (por ejemplo: máximo, sumatoria, productoria, etc.),  $n$  al número de entradas a la neurona  $N_i$  y  $w_i$  al peso.

Los valores de entrada se multiplican por los pesos anteriormente ingresados a la neurona. Por consiguiente, los pesos que generalmente no están restringidos cambian a la medida de influencia que tienen los valores de entrada. Es decir, que permiten que un gran valor de entrada tenga solamente una pequeña influencia, si estos son lo suficientemente pequeños.



**Figura 2.7: Ejemplo de red neuronal con dos capas de entradas y una capa de salida**  
Fuente: Jorge (2001)

La nomenclatura utilizada en la Figura 2.7 es la siguiente:

$in_{i1}$  = Entrada número 1 a la neurona  $N_i$ .

$w_{i1}$  = Peso correspondiente a  $in_{i1}$

$in_{i2}$  = Entrada número 2 a la neurona  $N_i$ .

$w_{i2}$  = Peso correspondiente a  $in_{i2}$

$ou_i$  = Salida de la neurona  $N_i$ .

El conjunto de todas las  $n$  entradas  $in_i = (in_{i1}, in_{i2}, \dots, in_{in})$  es comúnmente llamado "vector entrada"

## b. Función de Activación (activation function)

Una neurona biológica puede estar activa (excitada) o inactiva (no excitada); es decir, que tiene un “estado de activación”. Las neuronas artificiales también tienen diferentes estados de activación; algunas de ellas solamente dos, al igual que las biológicas, pero otras pueden tomar cualquier valor dentro de un conjunto determinado.

La función activación calcula el estado de actividad de una neurona; transformando la entrada global en un valor (estado) de activación, cuyo rango normalmente va de (0 a 1) o de (-1 a 1). Esto es así, porque una neurona puede estar totalmente inactiva (0 o -1) o activa (1).

Las funciones de activación más comúnmente utilizadas se detallan a continuación:

- **Función lineal**

$$f(x) = \begin{cases} -1 & x \leq -1 \\ x & -1 < x < 1 \\ 1 & x > 1 \end{cases} \quad (2.15)$$

- **Función logística o sigmoidea**

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.16)$$

Los valores de salida que proporciona esta función están comprendidos dentro de un rango que va de 0 a 1.

- **Función tangente hiperbólica**

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.17)$$

Los valores de salida de la función tangente hiperbólica están comprendidos dentro de un rango que va de -1 a 1

### c. Función Salida (output function)

El último componente que una neurona necesita es la función de salida. El valor resultante de esta función es la salida de la neurona  $i$  ( $out_i$ ); por ende, la función de salida determina qué valor se transfiere a las neuronas vinculadas. Si la función de activación está por debajo de un umbral determinado, ninguna salida se pasa a la neurona subsiguiente. Normalmente, no cualquier valor es permitido como una entrada para una neurona, por lo tanto, los valores de salida están comprendidos en el rango  $[0, 1]$  o  $[-1, 1]$ . También pueden ser binarios  $\{0, 1\}$  o  $\{-1, 1\}$ .

Dos de las funciones de salida más comunes son:

- **Ninguna:** este es el tipo de función más sencillo, tal que la salida es la misma que la entrada. Es también llamada función identidad.
- **Binaria:** 
$$\begin{cases} 1 & \text{si } act_i \geq \xi_i \\ 0 & \text{de lo contrario} \end{cases}$$
 donde  $\xi_i$  es el umbral.

#### 2.4.5. Validación de una red neuronal

Después del proceso de entrenamiento los pesos de las conexiones en la red neuronal quedan fijos. Como paso siguiente se debe comprobar si la red neuronal puede resolver nuevos problemas, del tipo general, para los que ha sido entrenada. Por lo tanto, con el propósito de validar la red neuronal se requiere de otro conjunto de datos, denominado conjunto de validación o testeo.

Cada ejemplo del conjunto de evaluación contiene los valores de las variables de entrada, con su correspondiente solución tomada; pero ahora esta solución no se le es otorgada a la red neuronal. Luego se compara la solución calculada para cada ejemplo de validación con la solución conocida.

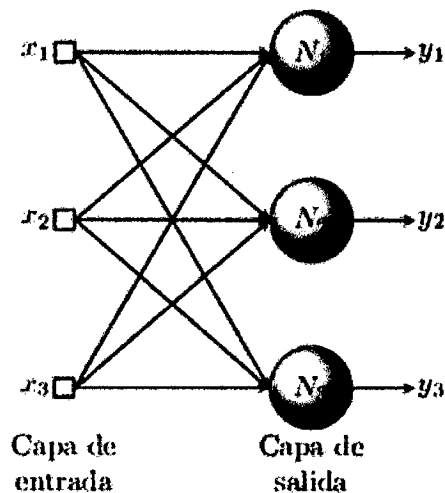
El nuevo ejemplo utilizado para la validación se identifica como  $E_u$  y su correspondiente salida correcta como  $A_u$  ( $u$  indica incógnita, en inglés). Ahora el problema es que hay que decidir cuando la salida de la red neuronal ha de considerarse como correcta.

## 2.4.6. Principales topologías de las redes neuronales artificiales

Según Jorge (2001), la topología o arquitectura de una red neuronal consiste en la organización y disposición de las neuronas en la misma, formando capas o agrupaciones de neuronas más o menos alejadas de la entrada y salida de dicha red. En este sentido, los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas.

### a. Redes Monocapa

En las redes monocapa, se establecen conexiones entre las neuronas que pertenecen a la única capa que constituye la red. Las redes monocapas se utilizan generalmente en tareas relacionadas con lo que se conoce como autoasociación (regenerar información de entrada que se presenta a la red de forma incompleta o distorsionada).



**Figura 2.8: Red neuronal monocapa**  
Fuente: Matallanas (2014)


### b. Redes Multicapa

Las redes multicapas son aquellas que disponen de un conjunto de neuronas agrupadas en varios (2, 3, etc.) niveles o capas. En estos casos, una forma para distinguir la capa a la que pertenece una neurona, consistiría en fijarse en el origen de las señales que recibe a la entrada y el destino de la señal de salida. Normalmente, todas las neuronas de una capa reciben señales de entrada desde

otra capa anterior (la cual está más cerca a la entrada de la red), y envían señales de salida a una capa posterior (que está más cerca a la salida de la red). A estas conexiones se las denomina conexiones hacia adelante o feedforward.

Sin embargo, en un gran número de estas redes también existe la posibilidad de conectar la salida de las neuronas de capas posteriores a la entrada de capas anteriores; a estas conexiones se las denomina conexiones hacia atrás o feedback.

Estas dos posibilidades permiten distinguir entre dos tipos de redes con múltiples capas: las redes con conexiones hacia adelante o redes feedforward, y las redes que disponen de conexiones tanto hacia adelante como hacia atrás o redes feedforward/feedback.



**Figura 2.9: Red neuronal multicapa**  
Fuente: Matallanas (2014)

### c. Conexión Entre Neuronas

La conectividad entre los nodos de una red neuronal está relacionada con la forma en que las salidas de las neuronas están canalizadas para convertirse en entradas de otras neuronas. La señal de salida de un nodo puede ser una entrada de otro elemento de proceso, o incluso ser una entrada de sí mismo (conexión autorrecurrente).

Cuando ninguna salida de las neuronas es entrada de neuronas del mismo nivel o de niveles precedentes, la red se describe como de conexión hacia adelante.



Cuando las salidas pueden ser conectadas como entradas de neuronas de niveles previos o del mismo nivel, incluyéndose ellas mismas, la red es de conexión hacia atrás. Las redes de propagación hacia atrás que tienen lazos cerrados son llamadas: sistemas recurrentes.

#### **2.4.7. Aplicaciones de las redes neuronales artificiales**

##### **El Perceptron**

El rango de tareas que el perceptron puede manejar es mucho mayor que simples decisiones y reconocimientos de patrones. Por ejemplo, se puede entrenar una red para formar el tiempo pasado de los verbos en inglés, leer texto en inglés y manuscrito. El perceptron multicapa (MLP) puede ser usado para la predicción de una serie de datos en el tiempo; tal ha sido su éxito en la medición de la demanda de gas y electricidad, además de la predicción de cambios en el valor de los instrumentos financieros.

Predicción de mercados financieros, diagnósticos médicos, el perceptron como una red codificadora, el perceptron aprende a sumar enteros. NETtalk es un perceptron que es capaz de transformar texto en inglés en sonido individual (representaciones fonéticas) y la pronunciación con la utilización de un sintetizador de voz; cuenta con aproximadamente 300 nodos de neuronas (siendo 80 en la capa escondida) y 20,000 conexiones individuales.

##### **Hopfield**

Las redes de hopfield se han aplicado a campos como la percepción el reconocimiento de imágenes y optimización de problemas, mostrando gran inmunidad al ruido y robustez. Incluso se han llegado a desarrollar chips específicos para este tipo redes. El estudio de las representaciones de secuencias temporales es un área de gran interés, con aplicaciones en reconocimiento automático de voces y movimientos.

Hopfield ha mostrado como aplicar los mismos principios con funciones de activación continuas como la función sigmoideal, con muy pocas modificaciones.

## **Kohonen**

Una vez entrenada, podemos usar a la red para clasificar patrones de entrada similares en el espacio n-dimensional. Una clase o grupo de patrones similares tiende a controlar una neurona específica, que representará el centro de una esfera n-dimensional (de radio unitario, pues normalizamos los datos sobre la unidad). Esa neurona resultará la más activada frente a los patrones más parecidos a su vector de pesos.

Después del aprendizaje, la clasificación consiste en presentar una entrada y seleccionar la unidad más activada. Además, el vector de pesos nos servirá para reconstruir el patrón de entrada.

## **Aplicaciones en el campo de las finanzas**

Existen una gran cantidad de herramientas para tratar diferentes problemas en el mundo de las finanzas.

### **Hedging**

El problema genérico de valorar opciones (option pricing) suele utilizar el modelo de Black&Scholes. La inclusión de volatilidades precisa refinamientos de este modelo. Muchos otros problemas de risk management se pueden tratar con técnicas similares.

### **Predicción de índices bursátiles**

El estudio del mercado de valores ha dado lugar a conceptos útiles pero parciales como son las resistencias, soportes, medias móviles, índices de Fibonacci, etc. Una red neuronal puede también ser entrenada con datos históricos de tipo fundamental, técnico y de mercado para realizar una selección de variables representativas y una posterior predicción. La red se basa pues en datos pasados, pero puede ser reentrenada constantemente para captar nuevos comportamientos del mercado. Constituye una herramienta de predicción dinámica.

## **Boosters**

Existen diferentes técnicas estadísticas para combinar predictores de varios tipos y establecer estrategias de mercado. Las redes neuronales son una de ellas. Las técnicas estadísticas avanzadas proporcionan herramientas cuantitativas para el tratamiento de grandes bancos de datos y la obtención de predicciones.

## **Aplicaciones para el Sector Bancario**

La banca viene ya utilizando sistemas expertos combinados con métodos estadísticos para tratar problemas de índole diversa.

## **Distribución**

Una oficina de Banco en una zona urbana debe tener en todo momento el mínimo efectivo posible para mantener su funcionamiento normal sin detrimento alguno para el cliente. Se trata pues de un problema de distribución con numerosas restricciones y condicionantes locales, de ahí la necesidad de técnicas estadísticas avanzadas.

## **Riesgo**

Una herramienta para ayudar a un director de zona urbana en el control del riesgo a la hora de conceder un crédito viene proporcionada bien por un sistema experto o por una red neuronal entrenada con casos fallidos.

## **Aplicaciones para Compañía Aseguradoras**

Las redes neuronales proporcionan varias herramientas para mejorar la comercialización de productos propios de compañías aseguradoras. Se destaca continuación tres tipos de redes que ya se han empleado en este tipo de mercado.

## **Predicciones de bajas**

A partir de un histórico (accidentes, edad, nivel socio-económico) sobre anteriores bajas, una red puede ser entrenada para detectar a un mes vista que

clientes tienen una alta probabilidad de dejar la compañía. La red otorga a cada cliente un nivel de fidelidad, mejorando la identificación de los clientes más proclives a dejar la tienda en el factor 3.

### **Targeted marketing**

Una red puede ser entrenada con los resultados de una compañía anterior para mejorar la selección de potenciales clientes en una nueva oferta de producto. A partir de datos históricos, la red ofrece una predicción de no comprar y, por lo tanto, reduce el conjunto de posibles clientes a contactar. Este método puede llegar a reducir a la mitad el número de posibles clientes a contactados manteniendo en un 90% el nivel de aceptación de una campaña.

### **Detección de fraude**

Una red neuronal puede ser entrenada con datos históricos para detectar fraude no evidente. La red busca correlaciones entre fraudes detectados y datos del cliente, para luego sondear los nuevos casos de accidentes.

Las redes neuronales proporcionan pues una herramienta cuantitativa sólida para la utilización de bases de datos de clientes en compañías aseguradoras.

## **Aplicaciones para Compañías del Sector Alimentación**

### **Predicción**

Una red neuronal puede ser entrenada con datos históricos para hacer predicción de ventas. Es posible, por ejemplo, alimentar a la red con datos de las ventas de tanto un camión como de todo un distribuidor para luego proporcionar una ayuda en la estimación de la predicción de las ventas futuras a corto y largo plazo.

### **Clasificación**

Las redes neuronales pueden aprender criterios de propensión a la compra de un determinado producto. Permiten también crear cestas de compra, es decir predecir qué nuevo producto se debe ofrecer a un determinado cliente dada su respuesta en el pasado.

## **Capítulo III: MATERIALES Y MÉTODOS**

### **3.1. Tipo y nivel de la investigación**

Puesto que el estudio busca una herramienta que permita realizar pronósticos a una realidad específica, la presencia del fenómeno El Niño en Piura, se trata de una investigación de tipo aplicada.

La investigación es Retrospectivo porque los datos con lo que se va a trabajar para el entrenamiento de la red neuronal han sido proporcionados por instituciones que se encargan de las mediciones de las variables involucradas. Esta investigación es longitudinal ya que las variables se han medido a lo largo del tiempo de manera continua, y se pretende generar otros posibles valores a partir de estos. Se considera analítica, porque contienen más de una variable, pues el fenómeno a estudiar es muy complejo.

Es explicativa, pues intenta demostrar la relación causa-efecto entre variables meteorológicas con la formación del fenómeno. Además, esta investigación es predictiva, ya que se encargará de la estimación de valores futuros del fenómeno.

### **3.2. Modelo teórico**

Considerando la base teórica revisada en el capítulo anterior y con la finalidad de desarrollar los objetivos planteados para modelar el pronóstico del Fenómeno El Niño, se propone el siguiente modelo de investigación para la implementación de ambos métodos:

- Implementación del modelo matemático de Winters, realizando previamente un análisis de la serie de tiempo con el propósito de obtener información sobre la tendencia y estacionalidad de la misma.
- Los pasos que se siguen para construir, entrenar y probar una red neuronal para predecir valores futuros de una serie de tiempo, son los siguientes:

#### **Escalamiento De Datos**

El escalamiento es la modificación de los datos originales a través de transformaciones tales que queden en un rango específico. Las diferencias en entre las dimensiones del análisis, incurren en el enmascaramiento de otras

diferencias. Esto quiere decir que tenemos que hacer uso de la transformación de escala para pasar todos los diferentes rangos a un solo rango definido (Meschino, G, 2006).

### **Patrones de entrenamiento y prueba**

Los valores de la serie de tiempo se dividen en dos conjuntos de datos: patrones de entrenamiento y patrones de prueba utilizados para evaluar la capacidad de generalización o predicción de la red.

### **Definir Topología de la RNA**

N° de entradas

N° de capas ocultas

N° de salida

Función de activación de los nodos de la capa oculta

Función de activación de la salida

### **Determinación de las entradas (p)**

Pueden considerarse:

- La Periodicidad de los datos.
- Pruebas de ensayo y error: en algunos casos considerar diferentes retrasos (6, 12, 18, ...) ayudaría a tener mayor precisión para la selección de la mejor topología de la red neuronal.

### **Determinación del número de nodos de la capa oculta**

Pueden realizarse pruebas por ensayo y error, agregando más nodos, y comparando los errores de ajuste y predicción.

### **Algoritmo de entrenamiento**

Utilizamos como función de entrenamiento el algoritmo *Levenberg – Marquardt* (trainlm), ya que este es muy utilizado para la resolución de problemas no lineales de mínimos cuadrados y en la solución de problemas genéricos de ajuste de curvas.

### **Pesos sinápticos**

Durante la etapa de entrenamiento de la red, se determinan iterativamente los pesos de las conexiones,  $W_{ji}$  que conectan a las neuronas  $i$  de la capa de entradas con las neuronas  $j$  de la capa oculta y  $W_{ji}$  para la transferencia entre la capa  $i$  oculta, y la  $j$  de salida.

### **Entrenamiento de la RNA seleccionada**

Para entrenar la red es necesario establecer el número máximo de ciclos o épocas y el error permitido de convergencia. Una vez definida la RNA, con su ecuación se generan los valores de la serie de tiempo ajustada o producida por la red, utilizando los patrones de entrenamiento.

### **Predicción**

Usando los pronósticos de las redes de las variables independientes se obtiene el valor de predicción  $t+1$ , calculando el error de la predicción.

## **3.3. Diseño de la investigación**

“Un experimento diseñado es una prueba o serie de pruebas en las cuales se inducen cambios deliberados en las variables de entrada de un proceso o un sistema, de manera que sea posible observar e identificar las causas de los cambios en la respuesta de salida” (Montgomery, 1991).

La presente investigación fue experimental por el hecho de que se ejerce un estricto control sobre el experimento por medio de la manipulación de las variables independientes con el fin de obtener resultados aceptables en el pronóstico del Fenómeno El Niño. Se utilizó para tal caso el análisis de varianza en disposición factorial de 2 factores (número de neuronas en la capa oculta y número de retardos) y para la red principal 3 factores (número de neuronas en la primera capa oculta, número de neuronas en la segunda capa oculta y número de épocas) con cuatro repeticiones; y el análisis de Duncan para determinar qué factor y a qué nivel proporciona mejores respuestas en el modelo predictivo. Como se muestra a continuación:

Cuadro 3.1: Análisis de varianza bifactorial

Factores de variación	Grados de libertad	Suma cuadrados	Cuadrados Medios	Fc	SIG
Tratamientos	8				
A	2				
B	2				
AXB	4				
ERROR	27				
TOTAL	35				
		CV =	%		

Fuente: Elaboración Propia.

Cuadro 3.2: Prueba de comparación de medias de Duncan bifactorial

CLAVE	Retardos	Variable	
		Valor	grupo
A1 A2 A3			
CLAVE	N° Neuronas ocultas		
B1 B2 B3			
CLAVE	Interacción		
A1B1 A1B2 A1B3 A2B1 A2B2 A2B3 A3B1 A3B2 A3B3			
CV =			

Fuente: Elaboración Propia.



Cuadro 3.3: Análisis de varianza trifactorial

Factores de variación	gl	SC	CM	Fc	SIG
Tratamientos	26				
A	2				
B	2				
C	2				
AXB	4				
AXC	4				
BxC	4				
AXBXC	8				
ERROR	81				
TOTAL	107				
		<b>CV =</b>			

Fuente: Elaboración Propia.

Cuadro 3.4: Análisis de Duncan trifactorial

CLAVE	N° Neuronas ocultas 1	PRECIPITACIONES	
A1			
A2			
A3			
CLAVE	N° Neuronas ocultas 2		
B1			
B2			
B3			
CLAVE	N° Épocas		
C1			
C2			
C3			
CLAVE	Interacción		
A1B1C1			
A1B1C2			
A1B1C3			
A1B2C1			
A1B2C2			
A1B2C3			
A1B3C1			
A1B3C2			
A1B3C3			
A2B1C1			
A2B1C2			
A2B1C3			
A2B2C1			
A2B2C2			
A2B2C3			
A2B3C1			
A2B3C2			
A2B3C3			
A3B1C1			
A3B1C2			
A3B1C3			
A3B2C1			
A3B2C2			
A3B2C3			
A3B3C1			
A3B3C2			
A3B3C3			
<b>CV =</b>			

Fuente: elaboración propia

### 3.4. Identificación de variables

Cuadro 3.5: Variable dependiente

VARIABLE	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	INDICADOR	ESCALA DE MEDIDA
<b>PRONÓSTICO DE LAS PRECIPITACIONES DE EL FENOMENO EL NIÑO</b>	(...) Se denomina "El Niño" al incremento de la temperatura superficial del agua del mar (TSM) en el litoral de la costa oeste de Sudamérica con ocurrencia de lluvias intensas (...) Actualmente, se le reconoce como el principal modulador de la variabilidad climática interanual." (SENAMHI, 2014)	Los valores de la temperatura superficial del mar para el pronóstico del FEN, se generarán utilizando redes neuronales como serie de tiempo	Temperatura Superficial del Mar en el Océano Pacífico	INTERVALO
		Los valores de la intensidad de los vientos alisios para el pronóstico del FEN, se generarán utilizando redes neuronales como serie de tiempo	Intensidad de los Vientos Alisios	INTERVALO
		Los valores de la precipitación en Piura para el pronóstico del FEN, obtenidos por el modelo de redes neuronales.	Precipitaciones	INTERVALO

Cuadro 3.6: Variables independientes

Variable	Definición Conceptual	Definición Operacional	Indicador	Escala De Medida
<b>REDES NEURONALES ARTIFICIALES</b>	<p>“Una red neural artificial es un procesador distribuido en paralelo de forma masiva que tiene una tendencia natural para almacenar conocimiento de forma experimental y lo hace disponible para su uso” (Aldabas, 2012)</p>	<p>Precipitaciones en Piura, medidas en mm</p>	<p>NUMERO DE NEURONAS EN CAPA DE SALIDA</p>	<p>RAZON</p>
		<p>Datos de Entrada</p> <ul style="list-style-type: none"> <li>- TSM en zona Niño 1+2</li> <li>- TSM en zona Niño 3</li> <li>- TSM en zona Niño 3.4</li> <li>- TSM en zona Niño 4</li> <li>- Velocidad de los Vientos Alisios</li> </ul>	<p>NUMERO DE NEURONAS EN CAPA DE ENTRADA</p>	<p>RAZON</p>
		<p>Se determina a través de:</p> <ul style="list-style-type: none"> <li>- Metodología de aprendizaje Backpropagation</li> </ul>	<p>PORCENTAJE DE ACIERTO</p>	<p>RAZON</p>

Fuente: Elaboración Propia

### 3.5. Muestra

Los datos utilizados fueron proporcionados por instituciones que se encargan de hacer seguimiento y registro permanente a las variables, se trabajará con información mensual entre los años 1979 y 2015, en este caso tenemos que los datos de las precipitaciones (mm) provienen de la estación meteorológica de Miraflores, Castilla, ubicada en la Universidad Nacional de Piura y cuyas coordenadas geográficas son, Latitud: 5°10'00.0"S, Longitud: 80°36'51.0"W y Altitud: 30 MSNM y fueron proporcionados por el Proyecto Especial Chira Piura. Los datos de temperatura superficial del Pacífico Sur (°C) conocido como zonas El Niño y la velocidad de los vientos alisios (m/s) en la zona 165°W - 110°W, fueron obtenidos gracias a la página web del *Climate Prediction Center*<sup>1</sup> de la NOAA. Todos los datos se encuentran en el anexo 4.

### 3.6. Método de análisis de datos

Para la implementación de la red neuronal artificial, se utilizó el lenguaje de programación e interfaz del software Matlab 2010. Para el estudio de las series de tiempo de la precipitación se ha utilizado el software Minitab v17, así mismo para la elaboración de pruebas estadísticas se ha hecho uso del software SPSS v23.

También se hizo uso del coeficiente de correlación de Pearson para conocer la medida de la relación lineal entre las variables.

---

<sup>1</sup> <http://www.cpc.ncep.noaa.gov/data>

## **Capítulo IV: RESULTADOS Y DISCUSIÓN**

### **4.1. Observación de la serie meteorológica**

En esta sección se analizará el comportamiento de las variables precipitaciones, temperatura superficial del mar en las zonas denominadas Niño 1+2, Niño 3, Niño 4 y Niño 3.4 además de la velocidad de los vientos, que servirán para entender las características estadísticas principales de las variables que intervienen en la formación del fenómeno El Niño.

Primero se graficará el comportamiento de las precipitaciones mensuales en Piura y luego se realizará un análisis que consiste en la obtención de características básicas de estadística como media, mediana, moda, desviación estándar, varianza, rangos mínimo y máximo, coeficiente de asimetría, promedios mensuales de cada variable además de un análisis del comportamiento a través del tiempo.

Luego haremos el análisis de la correlación de Pearson para todas las variables involucradas con la finalidad de entender la relación entre las mismas.

#### **4.1.1. Precipitaciones en Piura**

La siguiente figura muestra los valores que corresponden a la precipitación histórica en Piura para el periodo mensual contenido entre los años 1979 – 2015.




Figura 4.1: Análisis de precipitaciones (mm) en Piura 1979 - 2015

Fuente: elaboración propia

Como podemos observar en la figura 4.1, existen valores atípicos (valores máximos de la precipitación), que corresponden a los eventos El Niño extraordinarios que tuvieron lugar en los años 1983 y 1998; dichos valores son los que se pretende analizar, modelar y pronosticar.

Entre las principales características de las precipitaciones obtenidas de la figura 4.1 tenemos:


Cuadro 4.1: Características principales de precipitaciones

PRECIPITACIONES (mm)	
Media	15.33
Mediana	0.2
Moda	0
Desviación estándar	71.93
Varianza de la muestra	5174.34
Coefficiente de asimetría	7.7
Mínimo	0
Máximo	778.4

Fuente: elaboración propia

En el cuadro 4.1, se observó que la distribución de las precipitaciones en Piura tiene una asimetría hacia la derecha, es decir, la media es mayor que la mediana. Esta asimetría

es provocada por algunos valores muy grandes, además, la mayoría de los valores se ubica en la parte inferior de la distribución, es decir, en la zona izquierda; así mismo presenta una desviación estándar de 71.93 mm, que corresponde a la tendencia a variar por encima o por debajo de su media.



**Figura 4.2: Diagrama de precipitaciones promedio mensuales**  
Fuente: elaboración propia

En la figura 4.2 se presentan los valores promedios de las precipitaciones por mes del año considerando entre los años 1979 -2015 y en el podemos notar claramente que las precipitaciones en Piura tienen mayor presencia al inicio del año, el mes de febrero presenta un ligero aumento respecto a enero, en el mes de marzo se puede apreciar que se encuentra el pico más alto de la curva, por lo que puede considerarse así como el mes más lluvioso del año, a partir de ahí empieza un descenso hasta los meses de julio, agosto y septiembre que es donde se presenta el punto más bajo de la curva lo que demuestra que las precipitaciones en dichos meses, es casi nula; en el mes de octubre se presenta un leve incremento de las precipitaciones hasta el mes de diciembre (Ver anexo 1).



#### 4.1.2. Comportamiento de la temperatura superficial del mar en la formación del fenómeno El Niño

- **Temperatura superficial del mar en Zona Niño 1+2**

La zona El Niño 1+2, es el área del océano pacifico que se encuentra frente a las costas de Ecuador y el norte del Perú (Piura y Tumbes) por lo tanto, esta zona está directamente relacionada con nuestro clima y las anomalías que se puedan presentar en esta zona, repercutirán considerablemente en precipitaciones o sequias.




Figura 4.3: TSM zona Niño 1+2 entre 1979 - 2015  
Fuente: elaboración propia

Entre las principales características extraídas de la figura anterior, tenemos:

Cuadro 4.2: Características principales de tsm niño 1+2

TSM NIÑO 1+2 (°C)	
Media	23.42
Mediana	23.17
Moda	25.84
Desviación estándar	2.2
Varianza de la muestra	4.84
Coefficiente de asimetría	0.23
Mínimo	19.6
Máximo	29.12

Fuente: elaboración propia

En el cuadro 4.2 podemos observar, la distribución de la zona el niño 1+2 es simétrica, esto quiere decir que hay igual cantidad de datos a la derecha como a la izquierda de la media (23.42°C), y que los valores de la media con la mediana son muy cercanos, también se observó que temperatura superficial del mar presenta una desviación estándar de 2.20 °C que corresponde a la tendencia a variar por encima o por debajo de su media.





Figura 4.4: Diagrama de tsm en zona niño 1+2 promedio mensuales  
Fuente: elaboración propia

De la figura 4.3 obtenemos la figura 4.4 en la cual podemos notar claramente que la temperatura superficial del mar en promedio mensual en esta zona tiene una tendencia al alza desde el mes de enero y continua hasta el mes de marzo, a partir de ahí empieza a decrecer hasta el mes de septiembre, luego empieza

nuevamente el aumento de la temperatura hasta el mes de diciembre (Ver anexo 1).

- **Temperatura superficial del mar en Zona Niño 3**

La siguiente figura muestra los datos de la TSM en la zona Niño 3 en el periodo 1970 -2015, estos datos se encuentran en el anexo 4.



**Figura 4.5: TSM zona Niño 3 entre 1979 – 2015**

Fuente: elaboración propia

Entre las principales características extraídas de la figura anterior, tenemos:

**Cuadro 4.3: Características principales de tsm en zona niño 3**

TSM NIÑO 3 (°C)	
Media	26.1
Mediana	26.06
Moda	27.23
Desviación estándar	1.21
Varianza de la muestra	1.47
Coefficiente de asimetría	0.15
Mínimo	23.63
Máximo	29.24

Fuente: elaboración propia

Como podemos observar en el cuadro 4.3 la distribución de la zona el niño 3 es simétrica, esto quiere decir que hay igual cantidad de datos a la derecha como a

la izquierda de la media (26.10 °C), y que los valores de la media con la mediana son iguales, también se observó que temperatura superficial del mar presenta una desviación estándar de 1.21 °C que corresponde a la tendencia a variar por encima o por debajo de su media.




Figura 4.6: Diagrama de tsm en zona niño 3 promedio mensuales  
Fuente: elaboración propia

De la figura 4.5 obtenemos la figura 4.6 en la cual podemos notar claramente que la temperatura superficial del mar en promedio mensual en esta zona, tiene una tendencia al alza desde el mes de enero y continua hasta el mes de abril que es en donde se encuentra el pico más alto de la curva con 27.57 °C, a partir de ahí empieza a decrecer hasta el mes de septiembre, que es el punto más bajo de la curva con 24.0 °C, luego empieza nuevamente el aumento de la temperatura (Ver anexo 1).

- **Temperatura superficial del mar en Zona Niño 4**

La siguiente figura muestra los datos de la TSM en la zona Niño 3 en el periodo 1970 -2015, estos datos se encuentran en el anexo 4.




Figura 4.7: TSM zona Niño 4 entre 1979 – 2015

Fuente: elaboración propia

Entre las principales características extraídas de la figura anterior, tenemos:

Cuadro 4.4: Características principales de tsm en zona niño 4

TSM NIÑO 4 (°C)	
Media	28.66
Mediana	28.72
Moda	28.51
Desviación estándar	0.63
Varianza de la muestra	0.39
Coefficiente de asimetría	-0.52
Mínimo	26.81
Máximo	29.99

Fuente: elaboración propia

En el cuadro 4.4 podemos observar, la distribución de la zona el niño 4 es simétrica, esto quiere decir que hay igual cantidad de datos a la derecha como a la izquierda de la media (28.66 °C), y que los valores de la media con la mediana son muy cercanos, también se observó que temperatura superficial del

mar presenta una desviación estándar de 0.63 °C que corresponde a la tendencia a variar por encima o por debajo de su media.





Figura 4.8: Diagrama de tsm en zona niño 4 promedio mensuales  
Fuente: elaboración propia

De la figura 4.7 obtenemos la figura 4.8 en la cual podemos notar claramente que la temperatura superficial del mar en promedio mensual en esta zona, tiene una tendencia al alza desde el mes de febrero y continua hasta el mes de mayo donde se mantiene hasta junio alcanzando los picos más altos, a partir de ahí empieza a decrecer hasta el mes de septiembre donde se mantiene hasta octubre, luego empieza nuevamente la disminución de la temperatura (Ver anexo 1).

- **Temperatura superficial del mar en Zona Niño 3.4**

La siguiente figura muestra los datos de la TSM en la zona Niño 3 en el periodo 1970 -2015, estos datos se encuentran en el anexo 4.



**Figura 4.9: TSM zona Niño 3.4 entre 1979 – 2015**  
**Fuente: elaboración propia**

Entre las principales características extraídas de la figura anterior, tenemos:


**Cuadro 4.5: Características principales de la tsm en zona niño 3.4**

<b>TSM NIÑO 3.4 (°C)</b>	
Media	27.17
Mediana	27.2
Moda	27.1
Desviación estándar	0.92
Varianza de la muestra	0.85
Coefficiente de asimetría	-0.13
Mínimo	24.81
Máximo	29.14

Fuente: elaboración propia

Como podemos observar en el cuadro 4.5, la distribución de la zona el niño 4 es simétrica, esto quiere decir que hay igual cantidad de datos a la derecha como a la izquierda de la media (27.17 °C), y que los valores de la media con la mediana son iguales o muy cercanos, también se observó que temperatura

superficial del mar presenta una desviación estándar de 0.92 °C que corresponde a la tendencia a variar por encima o por debajo de su media.




**Figura 4.10: Diagrama de tsm en zona niño 3.4 promedio mensuales**  
Fuente: elaboración propia

De la figura 4.9 obtenemos la figura 4.10 en la cual podemos notar claramente que la temperatura superficial del mar en promedio mensual en esta zona, tiene una tendencia al alza desde el mes de enero y continua hasta el mes de mayo, a partir de ahí empieza a decrecer hasta el mes de diciembre (Ver anexo 1).

#### **4.1.3. Comportamiento de la velocidad de los vientos alisios en la formación del fenómeno El Niño**

La siguiente figura muestra los datos de la TSM en la zona Niño 3 en el periodo 1970 -2015, estos datos se encuentran en el anexo 4, en él se muestran valores positivos y negativos de esta variable, esto es porque los vientos alisios que siguen su recorrido normal (de este a oeste) se consideran positivos, mientras que los que presentan anomalías (de oeste a este) se consideran negativos.





**Figura 4.11: Velocidad de vientos alisios entre 1979 – 2015**  
**Fuente: elaboración propia**


Entre las principales características extraídas de la figura anterior, tenemos:

**Cuadro 4.6: Características principales de velocidad de vientos**

<b>VELOCIDAD DE VIENTOS ALISIOS (m/s)</b>	
Media	6.12
Mediana	5.5
Moda	7.5
Desviación estándar	8.07
Varianza de la muestra	65.13
Coficiente de asimetría	0.34
Mínimo	-9.2
Máximo	27.3

Fuente: elaboración propia

En el cuadro 4.6 podemos observar, la distribución de la velocidad de los vientos alisios presenta una asimétrica, hacia la derecha, es decir, la media es mayor que la mediana. Esta asimetría es provocada por algunos valores grandes, además, la mayoría de los valores se ubica en la parte inferior de la distribución, es decir, a la izquierda, además, se observó que la velocidad de los vientos alisios presenta una desviación estándar de 8.07 m/s que corresponde a la tendencia a variar por encima o por debajo de su media.



**Figura 4.12: Diagrama de velocidad de vientos alisios promedio mensuales**  
**Fuente: elaboración propia**

De la figura 4.11 obtenemos la figura 4.12 en la cual podemos notar claramente que la velocidad de los vientos alisios, tienen una tendencia a disminuir en promedio desde el mes de enero hasta el mes de setiembre que es donde se obtiene el punto más bajo, a partir de ahí empieza a aumentar hasta el mes de diciembre (Ver anexo 1).

#### 4.1.4. Correlación de Pearson

En el cuadro 4.7 se analizan las relaciones existentes entre las variables involucradas en el modelo mediante el análisis de correlaciones de Pearson, esto se realiza con la finalidad de saber cuáles son las variables independientes que realmente están relacionadas con la variable dependiente precipitaciones:

Cuadro 4.7: Correlaciones de Pearson para las variables del modelo

MATRIZ DE CORRELACIONES							
		Precipitación Piura	Niño 1+2	Niño 3	Niño 4	Niño 3.4	Velocidad Del Viento
Precipitación Piura	Correlación de Pearson	1	0.402**	0.365**	0.002	0.253**	-.110*
Niño 1+2	Correlación de Pearson	0.402**	1	0.796**	-0.065	0.398**	0.382**
Niño 3	Correlación de Pearson	0.365**	0.796**	1	0.387**	0.836**	-.093*
Niño 4	Correlación de Pearson	0.002	-0.065	0.387**	1	0.788**	-.565**
Niño 3.4	Correlación de Pearson	0.253**	0.398**	0.836**	0.788**	1	-.458**
Velocidad Del Viento	Correlación de Pearson	-.110*	.382**	-.093*	-.565**	-.458**	1

\*\* . La correlación es significativa en el nivel 0,01 (bilateral).

\* . La correlación es significativa en el nivel 0,05 (bilateral).

Fuente: Elaboración Propia

Verificamos que existe correlación entre la variable dependiente precipitaciones y las variables independientes tsm en las zonas El Niño y velocidad de vientos alisios, con excepción de la relación, precipitación - temperatura Niño 4; de igual forma podemos verificar que existe correlación interna entre las temperaturas, con excepción de Niño 1+2 - Niño 4, en cuanto a las otras correlaciones se entiende que la conexión de una y otra temperatura es en cuanto al incremento o decremento que se da al mismo tiempo.

Con este estudio podemos verificar cuales son las variables que formarán parte de los modelos a construir, por lo tanto, podemos decir que, las variables independientes temperaturas superficiales del mar y velocidad de vientos alisios están correlacionadas con la variable dependiente precipitaciones, con excepción de la variable tsm Niño 4, sin embargo, se ha decidido incluirla en el modelo, ya que se encuentra ubicada en la zona de formación del fenómeno El Niño.

## 4.2. Análisis de la serie de tiempo

Antes de realizar la estimación del modelo matemático de Winters, analizaremos la presencia de tendencia y estacionalidad de la precipitación en Piura, los que deben ser coherentes con la visualización del comportamiento que siguen los datos de la precipitación donde se observa que no siguen un comportamiento lineal, por el contrario, es altamente no lineal y completamente errático con valores atípicos precisamente considerados como los de Niños extraordinarios.

Para las siguientes pruebas se utilizó el software estadístico Minitab 16 el cual nos permite realizar el análisis con facilidad mediante sus diferentes aplicaciones, para nuestro caso utilizamos el análisis de series de tiempo tanto de tendencia como de estacionalidad.

### 4.2.1. Análisis de la tendencia

Para el primer análisis es necesario ajustar la tendencia por medio del estudio de la tendencia estática y dinámicamente modelar el componente estacional en los residuos.

Al realizar el análisis correspondiente con los datos de las precipitaciones que se encuentran en el anexo 4, obtenemos la siguiente ecuación y sus medidas de exactitud:

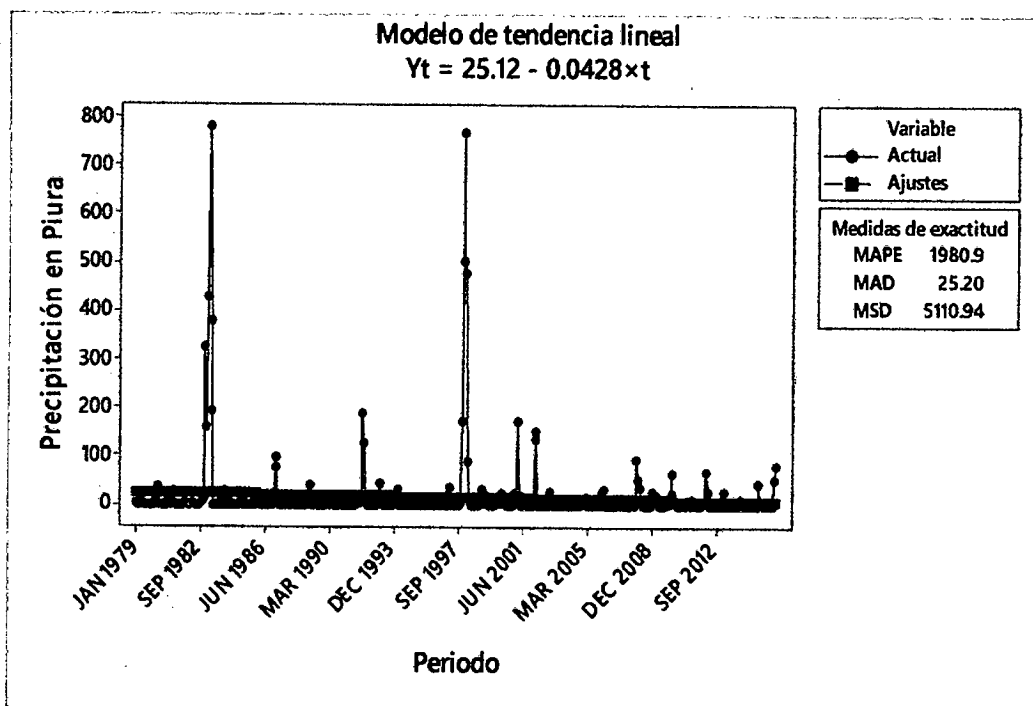
$$Y_t = 25.12 - 0.0428 \times t \quad (4.1)$$

Medidas de exactitud

$$\text{MAPE} = 1980.94\%$$

$$\text{MAD} = 25.20$$

$$\text{MSD} = 5110.94$$



**Figura 4.13:** Gráfica de análisis de tendencia de precipitaciones en Piura 1979 - 2015  
Fuente: elaboración propia

La figura 4.13 nos muestra valores muy elevados de MAPE, MAD y MSD que indican que el modelo de tendencia lineal no es apropiado para pronosticar la precipitación, el coeficiente  $-0.0428$  indica una tendencia decreciente explicada por los fenómenos del niño pasado y los ciclos estacionarios del primer trimestre de cada año correspondiente al verano de la región.

#### 4.2.2. Análisis de estacionalidad

En este análisis encontraremos los índices estacionales, que son necesarios cuando existe estacionalidad o ciclos, se utilizan cuando existen diferencias muy marcadas entre ciclos, por eso se hace necesario encontrar un índice que nos permita un ajuste por cada periodo; nosotros trabajaremos con 12 ciclo ya que las fluctuaciones de las precipitaciones ocurren anualmente.

##### 4.2.2.1. Análisis de estacionalidad con tendencia

Al realizar el análisis correspondiente con los datos de las precipitaciones que se encuentran en el anexo 4, obtenemos la siguiente ecuación de tendencia ajustada:

$$Y_t = 68.6 - 0.1543 \times t \quad (4.2)$$

Así mismo, en el cuadro 4.8 se muestran los Índices estacionales:

Cuadro 4.8: Índices estacionales – análisis de estacionalidad con tendencia

Período	Índice
1	0.82351
2	2.99643
3	6.02646
4	1.71959
5	0.12189
6	0.00000
7	0.00000
8	0.00000
9	0.00000
10	0.02780
11	0.03327
12	0.25105

Fuente: elaboración propia

Medidas de exactitud:

MAPE = 2853.68% MAD = 35.99 MSD = 8568.21




Figura 4.14: Gráfica de análisis de estacionalidad con tendencia

Fuente: elaboración propia

La figura 4.14 nos muestra que el valor MAPE, MAD y MSD es mayor al anterior, esto debido a que el intercepto del modelo de tendencia aumentó y no

sigue el recorrido de los valores, indican entonces que el modelo de tendencia lineal y multiplicativo no es apropiado para pronosticar la precipitación, el coeficiente  $-0.1543$  indica una tendencia decreciente explicada por los fenómenos del niño pasado y los ciclos estacionarios del primer trimestre de cada mes correspondiente al verano de la región.

#### 4.2.2.2. Análisis de estacionalidad sin tendencia

Al realizar el análisis correspondiente con los datos de las precipitaciones que se encuentran en el anexo 4, obtenemos en el cuadro 4.9 los siguientes índices estacionales:

Cuadro 4.9: Índices estacionales – análisis de estacionalidad sin tendencia

Período	Índice
1	0.823510
2	2.996430
3	6.026460
4	1.719590
5	0.121890
6	0.000000
7	0.000000
8	0.000000
9	0.000000
10	0.027800
11	0.033270
12	0.251050

Fuente: elaboración propia

Medidas de exactitud

MAPE = 2494.83%    MAD = 35.67    MSD = 7213.01

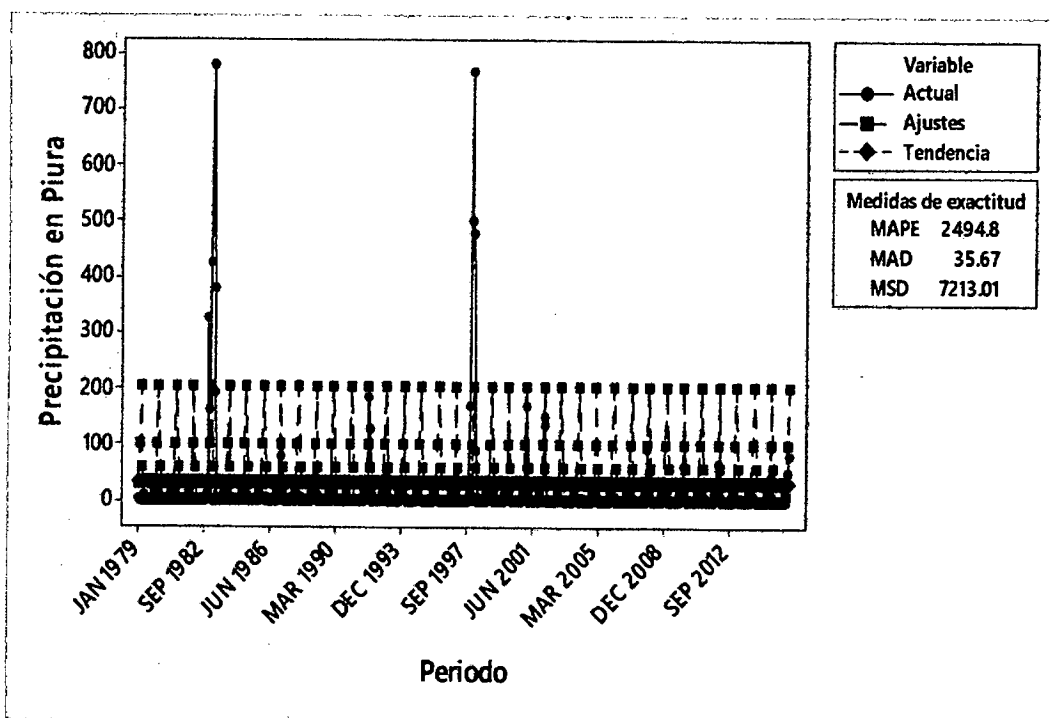


Figura 4.15: Gráfica de análisis de estacionalidad sin tendencia

Fuente: elaboración propia

La figura 4.15 nos muestra que el valor MAPE, MAD y MSD es menor al anterior, esto debido a que no se considera la tendencia por considerar el proceso estacionario en media sigue mejor el recorrido de los valores indican entonces que el modelo multiplicativo sin tendencia es mejor, aunque no es apropiado para pronosticar la precipitación.

Después de haber analizado las componentes de tendencia y estacionalidad de los datos de precipitaciones, podemos decir que ambos componentes no tienen presencia en dicha serie de tiempo, esto confirma que el fenómeno en estudio es completamente errático, por lo que en el modelo de Winters no se hará uso de estas componentes.



### 4.3. Modelo de Winters

A continuación, se creará el modelo correspondiente de Winters, teniendo presente los resultados obtenidos en los análisis previos de tendencia y estacionalidad, en el vemos que no existe presencia de ambos componentes en la serie de tiempo, por lo tanto, las constantes correspondientes ( $\gamma$  y  $\delta$ ) serán iguales a cero, mientras que  $\alpha$  será ajustado por el software Minitab.

Constantes de suavización:

$$\alpha (\text{nivel}) = 0.999; \gamma (\text{tendencia}) = 0.000; \delta (\text{estacional}) = 0.000$$

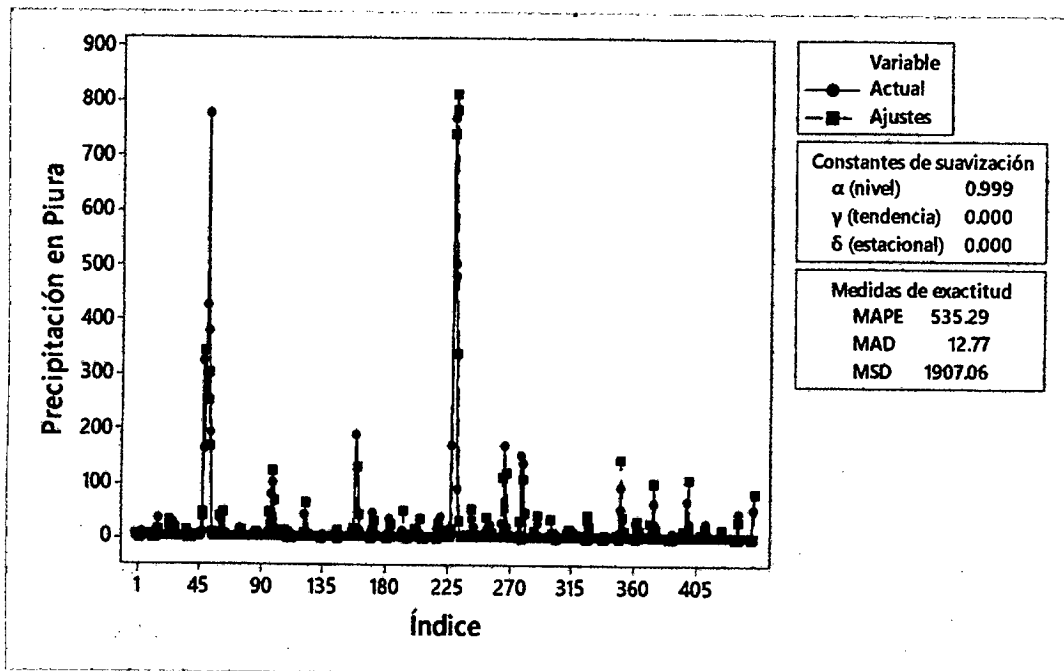


Figura 4.16: Gráfica del modelo de Winters para precipitaciones  
Fuente: elaboración propia

La figura 4.16 nos muestra que el modelo de Winters de acuerdo a las medidas de exactitud de MAPE = 535.29%; MAD = 12.77 y MSD = 1907.06 es el que mejor pronostica y ajusta los datos.

Entonces, reemplazando el valor de las constantes en las fórmulas 2.11, 2.12 y 2.13, quedarían de la siguiente forma:

$$L_t = 0.999 * \left( \frac{Y_t}{S_{t-p}} \right) + 0.001 * [L_{t+1} + T_{t+1}] \quad (4.3)$$

$$T_t = T_{t-1} \quad (4.4)$$

$$S_t = S_{t-p} \quad (4.5)$$

Para encontrar los valores del pronóstico, los valores encontrados en las ecuaciones 4.3, 4.4 y 4.5 se reemplazan en la ecuación de pronóstico 2.14, la cual quedaría de la siguiente forma:

$$Y_{est} = (L_{t-1} + T_{t-1}) * S_{t-p} \quad (4.6)$$

Como resultado obtenemos el cuadro 4.11 con el pronóstico de precipitaciones para el periodo 2016 (enero – junio):

Cuadro 4.10: Pronóstico de precipitaciones enero –junio 2016 con método de Winters

		Precipitación (mm)	Pronóstico WINTERS Precipitación (mm)	Error
2016	ENE	0.8	0	0.8
	FEB	52	0.3561	51.6439
	MAR	82	80.4059	1.5941
	ABR	0	57.2984	-57.2984
	MAY	0	18.2448	-18.2448
	JUN	0	7.9373	-7.9373

Fuente: elaboración propia

Del cuadro anterior, vemos que el pronóstico con el método de Winters solo se acerca en el mes de marzo donde presenta el error más pequeño (1.5941), sin embargo, en los otros meses el error es mayor.

#### **4.4. Diseño de red neuronal artificial para el pronóstico del fenómeno El Niño**

El diseño de la red neuronal que modele el comportamiento de las precipitaciones del fenómeno El Niño, se hace en dos etapas, la primera etapa en la que se considera cada variable de entrada como una serie de tiempo y se obtiene como salida el mes siguiente, este valor ingresa a la red que permite pronosticar el valor de la precipitación en el mes siguiente, y/o de los 6 meses siguiente; y una segunda etapa en la que se construye la red neuronal como un perceptron multicapa en el cual las entradas a la red lo constituyen las cinco variables independientes como (temperatura superficial del mar en las zonas Niño 1+2, zona Niño 3, zona Niño 4, zona Niño 3.4 y velocidad de los vientos alisios) que explican la variable de salida, esto es la variable dependiente precipitación; en ambas etapas ingresan a las redes neuronales los valores de las variables previamente normalizados entre -1 y 1; este diseño permitió a través de los ensayos encontrar patrones de comportamiento que siguen con una alta precisión el comportamiento real de las precipitaciones ocurridas durante todo el horizonte de planeamiento, además permite predecir o extrapolar el comportamiento de las precipitaciones seis meses después, conociendo los datos de entrada estimados con las redes neuronales.

##### **4.4.1. Diseño de red neuronales para el pronóstico de variables explicativas; primera fase.**

###### **Selección de RNA con mejor resultados**

Para realizar la selección de la red neuronal que tenga mejores resultados se ha asignado 2 factores de variación, cantidad de neuronas en la capa oculta y cantidad de retardos, se realizará tanto el análisis de varianza como la comparación de medias de Duncan. En el anexo 2 se encuentran los datos recolectados en las corridas de las redes y los análisis de varianza para cada variable donde se puede observar que:

El análisis de varianza para la variable tsm en la zona Niño 1+2 realizado en el anexo 2.a, muestra que el factor A, cantidad de retardos (4 - 8 - 12), presenta una influencia significativa al 99% en el error cuadrático medio. Así mismo el factor B, cantidad de neuronas en la capa oculta (5 - 15 - 25), también presenta

una influencia significativa estadísticamente al 95%. Sin embargo, la interacción de ambos factores no presenta una influencia comportándose estadísticamente iguales sobre el error cuadrático medio utilizando el análisis de varianza. El análisis tuvo un coeficiente de variación de 0.1234%.

El análisis de varianza para la variable tsm en la zona Niño 3 realizado en el anexo 2.b, muestra que el factor A, cantidad de retardos (4 - 8 - 12), presenta una influencia significativa al 99% en el error cuadrático medio. El factor B, cantidad de neuronas en la capa oculta (5 - 15 - 25), es indiferente estadísticamente a la respuesta del error cuadrático medio. Así mismo, la interacción de ambos factores tampoco presenta una influencia comportándose estadísticamente iguales sobre el error cuadrático medio utilizando el análisis de varianza. El análisis tuvo un coeficiente de variación de 0.0581%.

El análisis de varianza para la variable tsm en la zona Niño 4 realizado en el anexo 2.c, muestra que el factor A, cantidad de retardos (4 - 8 - 12), presenta una influencia significativa al 99% en el error cuadrático medio al igual que el factor B, cantidad de neuronas en la capa oculta (5 - 15 - 25). Sin embargo, la interacción de ambos factores no presenta una influencia comportándose estadísticamente iguales sobre el error cuadrático medio utilizando el análisis de varianza. El análisis tuvo un coeficiente de variación de 0.0041%.

El análisis de varianza para la variable tsm en la zona Niño 3.4 realizado en el anexo 2.d, muestra que el factor A, cantidad de retardos (4 - 8 - 12), presenta una influencia significativa al 99% en el error cuadrático medio al igual que el factor B, cantidad de neuronas en la capa oculta (5 - 15 - 25). Sin embargo, la interacción de ambos factores no presenta una influencia comportándose estadísticamente iguales sobre el error cuadrático medio utilizando el análisis de varianza. El análisis tuvo un coeficiente de variación de 0.0215%.

Por último, el análisis de varianza para la variable velocidad de vientos alisios realizado en el anexo 2.e, muestra que el factor A, cantidad de retardos (4 - 8 - 12), presenta una influencia significativa al 99% en el error cuadrático medio al igual que el factor B, cantidad de neuronas en la capa oculta (8 - 16 - 24). La interacción de ambos factores también presenta un efecto significativamente

diferente sobre el error cuadrático medio utilizando el análisis de varianza. El análisis tuvo un coeficiente de variación de 0.0372%.

Al realizar el análisis de comparación de medias de Duncan, para todas las variables de las series temporales, relacionadas con la temperatura superficial del mar, se muestran en el cuadro 4.11, se observa que:

Para la tsm en la zona Niño 1+2 en el factor retardos los niveles 8 y 12 se comportan mejor y estadísticamente iguales sin embargo el nivel 8 tiene numéricamente un menor error medio cuadrático, (es decir se utiliza 8 valores de la serie para pronosticar el que sigue); en el factor número de neuronas en la capa oculta los niveles 15 y 25 alcanzan los menores errores comportándose estadísticamente iguales, sin embargo numéricamente el nivel que obtuvo el menor error cuadrático medio es 15 neuronas en la capa oculta. El análisis comparativo de Duncan con respecto a las interacciones se observa que las combinaciones que alcanzaron mejores resultados son las interacciones del grupo “a” relacionadas con el factor retardos de nivel 8, y se comportan estadísticamente iguales que las interacciones de 12x15 y 12x25; sin embargo, numéricamente el menor error cuadrático medio es alcanzado por la interacción 12x25.

Para la tsm en la zona Niño 3 en el factor retardos los niveles 8 y 12 se comportan mejor y estadísticamente iguales sin embargo el nivel 12 tiene numéricamente un menor error medio cuadrático, (es decir se utiliza 12 valores de la serie para pronosticar el que sigue); en el factor número de neuronas en la capa oculta el 25 alcanza el menor error. El análisis comparativo de Duncan con respecto a las interacciones se observa que las que alcanzaron mejores resultados son las interacciones del grupo “a”, 8x25, 12x15 y 12x25 y se comportan estadísticamente iguales; sin embargo, numéricamente el menor error cuadrático medio es alcanzado por la interacción 12x25.

Para la tsm en la zona Niño 4 en el factor retardos el nivel 8 es el que se comporta mejor estadísticamente y numéricamente tiene un menor error medio cuadrático, (es decir se utiliza 8 valores de la serie para pronosticar el que sigue); en el factor número de neuronas en la capa oculta los niveles 15 y 25

alcanzan los menores errores comportándose estadísticamente iguales, sin embargo, numéricamente el nivel que obtuvo el menor error cuadrático medio es 25 neuronas en la capa oculta. El análisis comparativo de Duncan con respecto a las interacciones se observa que las que alcanzaron mejores resultados son las interacciones del grupo “a”, 8x15, 8x25, 12x15 y 12x25 y se comportan estadísticamente iguales; sin embargo, numéricamente el menor error cuadrático medio es alcanzado por la interacción 12x25.

Para la tsm en la zona Niño 3.4 en el factor retardos el nivel 4 es el que se comporta mejor estadísticamente y numéricamente tiene un menor error medio cuadrático, (es decir se utiliza 4 valores de la serie para pronosticar el que sigue); en el factor número de neuronas en la capa oculta el nivel 25 es el que se comporta mejor estadísticamente y numéricamente tiene un menor error medio cuadrático, es decir se utilizaran 25 neuronas en la capa oculta. El análisis comparativo de Duncan con respecto a las interacciones se observa que las que alcanzaron mejores resultados son las interacciones del grupo “a”, 12x15 y 12x25, y se comportan estadísticamente iguales, sin embargo, numéricamente el menor error cuadrático medio es alcanzado por la interacción 12x25.

Cuadro 4.11: Análisis de Duncan a un nivel de significancia de 0.05 y 27 grados de libertad del cuadrado medio del error, de tsm Niño 1+2

CLAVE	Retardos	Niño 1+2		Niño 3		Niño 4		Niño 3.4	
A1	4	0.047284	b	0.037715	b	0.017177	c	0.017177	a
A2	8	0.007143	a	0.008849	a	0.010906	b	0.010906	b
A3	12	0.008897	a	0.008677	a	0.010289	a	0.010289	c
CLAVE	N° Neuronas ocultas								
B1	5	0.024426	b	0.0202875	b	0.013994	b	0.017731	b
B2	15	0.018963	a	0.0178927	ab	0.012296	a	0.016491	b
B3	25	0.019934	a	0.017061	a	0.012082	a	0.013959	a
CLAVE	Interacción								
A1B1	4x5	0.049012	c	0.037622	c	0.018284	d	0.026789	f
A1B2	4x15	0.04704	c	0.037638	c	0.016921	c	0.025146	ef
A1B3	4x25	0.045801	c	0.037886	c	0.016325	c	0.022872	e
A2B1	8x5	0.008343	a	0.010056	ab	0.011896	b	0.0135	cd
A2B2	8x15	0.007154	a	0.008617	ab	0.010439	a	0.014693	d
A2B3	8x25	0.005932	a	0.007874	a	0.010384	a	0.011112	bc
A3B1	12x5	0.015925	b	0.013185	b	0.01180	b	0.012906	cd
A3B2	12x15	0.005608	a	0.007423	a	0.009529	a	0.009635	a
A3B3	12x25	0.005157	a	0.005423	a	0.009528	a	0.007895	a
<b>CV =</b>		<b>0.1234%</b>		<b>0.0581%</b>		<b>0.0041%</b>		<b>0.0215%</b>	

Fuente: elaboración propia

El análisis de comparación de medias de Duncan, para la variable velocidad de vientos alisios, se muestran en el cuadro 4.12, se observa que el factor retardos el nivel 12 es el que se comporta mejor estadísticamente y numéricamente tiene un menor error medio cuadrático, (es decir se utiliza 12 valores de la serie para pronosticar el que sigue); en el factor número de neuronas en la capa oculta los niveles 16 y 24 alcanzan los menores errores comportándose estadísticamente iguales, sin embargo numéricamente el nivel que obtuvo el menor error cuadrático medio es 24 neuronas en la capa oculta. El análisis comparativo de Duncan con respecto a las interacciones se observa las que alcanzaron mejores resultados son las interacciones del grupo “a”, 12x16 y 12x24, y se comportan estadísticamente iguales, sin embargo, numéricamente el menor error cuadrático medio es alcanzado por la interacción 12x24.

Cuadro 4.12: Análisis de Duncan a un nivel de significancia de 0.05, y 27 grados de libertad del cuadrado medio del error, velocidad de vientos

CLAVE	Retardos	Velocidad de vientos	
A1	4	0.072243	c
A2	8	0.058969	b
A3	12	0.04134	a
CLAVE	N° Neuronas ocultas		
B1	8	0.064218	b
B2	16	0.055634	a
B3	24	0.0527	a
CLAVE	Interacción		
A1B1	4x8	0.073844	e
A1B2	4x16	0.069821	de
A1B3	4x24	0.073064	e
A2B1	8x8	0.065376	cd
A2B2	8x16	0.059154	bc
A2B3	8x24	0.052376	b
A3B1	12x8	0.053436	b
A3B2	12x16	0.037925	a
A3B3	12x24	0.03266	a
<b>CV =</b>		<b>0.0372%</b>	

El análisis de varianza y el análisis de comparación de medias de Duncan para las variables independientes se ha realizado con la finalidad de poder saber cuál es el mejor modelo para cada una de ellas y podemos ver que son aquellos que tienen menor error cuadrático medio en la categoría “a”; los modelos elegidos serán implementados en el siguiente en el apartado 4.4.2 y serán los que nos determinen el comportamiento de cada variable a través del tiempo.



#### 4.4.2. Estructura de la RNA seleccionadas y resultados durante su ejecución

Los datos utilizados son mensuales y existen registros de 37 años comprendidos entre 1979 hasta 2015 (444 patrones) y se encuentran en el anexo 4.

El objetivo de cualquier algoritmo de entrenamiento es hacer mínimo el error cuadrado medio, pero la experiencia ha demostrado que las redes tienden a sobreajustar los datos. Por esta razón es usual destinar el 70% de la muestra para el entrenamiento y el 30% para la prueba del modelo (validación y testeo), los cuales entrarán a la red escalonados en el rango de -1 y 1; los datos de los meses entre enero – junio del año 2016 se tomarán como muestra para confrontarlos con los valores pronosticados de la red neuronal. El número de neuronas corresponde al elegido en el diseño anterior. Los pesos y bias de las redes neuronales se encuentran en el anexo 8.

En esta sección haremos uso de Matlab ya que cuenta con las herramientas necesarias para el diseño e implementación de las redes neuronales, con este software podemos ver en tiempo real el entrenamiento de red y como varían los principales parámetros, nos muestra una gráfica con el comportamiento durante el entrenamiento, además nos presenta una gráfica que muestra el ajuste del modelo.

##### 4.4.2.1. TSM en Zona Niño 1+2


Los parámetros definidos para la red son:

Número total de patrones de entrada	: 432
Número de patrones de entrenamiento	: 70%
Número de patrones de validación y testeo	: 30%
Número de neuronas en la capa de entrada	: 12
Número de neuronas en la capa oculta	: 25
Número de neuronas en la capa de salida	: 1

La función de activación en cada neurona :  $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

Como resultado tenemos:

Neural Network



Algorithms

Training: Levenberg-Marquardt (trainlm)  
 Performance: Mean Squared Error (mse)  
 Data Division: Specified (1:2:1)

Progress

Epochs:	0	510 iterations	1000
Time:		0:00:35	
Performance:	0.621	0.000155	1.00e-10
Gradient:	1.00	2.77e-06	1.00e-10
Mu:	0.00100	1.00e-05	1.00e+10
Validation Checks:	0	50	50

Plots

- Performance (plotperformance)
- Training State (plottrainingstate)
- Regression (plotregression)

Plot Interval: 1 epochs

Opening Regression Plot

Step Training  Cancel

Figura 4.17: Entrenamiento de rna para tsm en niño 1+2  
 Fuente: elaboración propia

Como podemos ver en la figura que el proceso de entrenamiento se detuvo en la época 510, esto sucedió porque se completó el número de validaciones.


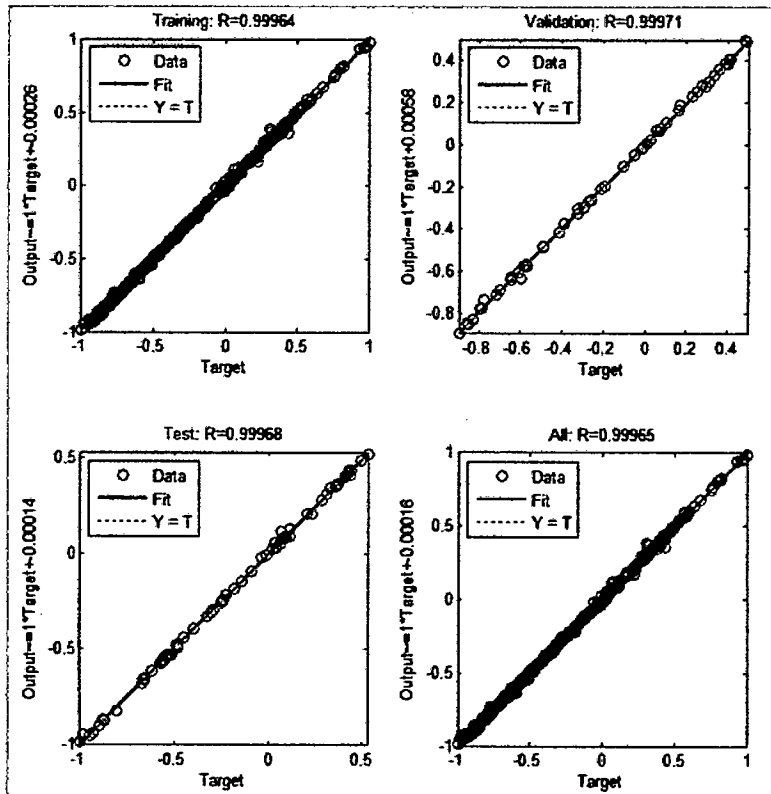


Figura 4.18: Aprendizaje de rna para temperatura tsm de niño 1+2  
 Fuente: elaboración propia

La figura 4.18 muestra cómo va disminuyendo el error a través del tiempo hasta alcanzar su valor mínimo durante el entrenamiento.



**Figura 4.19: Ajuste del modelo de rna para tsm niño 1+2**  
**Fuente: elaboración propia**

La figura 4.19 nos muestra las regresiones entre la salida de la red y los patrones de entrada. Como podemos observar los datos de salida se adecuan bastante bien a los datos de entrenamiento, validación y test; esto se ve reflejado en el valor del coeficiente de correlación general que es 0.99965.

Como resultado obtenemos el cuadro 4.13 con el pronóstico de la tsm en zona niño 1+2 para el periodo 2016 (enero – junio):

Cuadro 4.13: Pronóstico enero – junio 2016 de tsm niño 1+2

		Niño 1+2	Pronóstico RED Niño 1+2	Error
<b>2016</b>	<b>ENE</b>	26.21	24.87	1.34
	<b>FEB</b>	27.29	27.86	-0.57
	<b>MAR</b>	27.54	26.89	0.65
	<b>ABR</b>	25.97	25.73	0.24
	<b>MAY</b>	25.05	25.86	-0.81
	<b>JUN</b>	23.73	24.57	-0.84

Fuente: elaboración propia

Del cuadro anterior, vemos que el pronóstico con redes neuronales artificiales de la tsm en la zona niño 1+2 se acercan mucho a los valores reales por lo que presenta un error muy pequeño en todos los meses.

#### 4.4.2.2. TSM en Zona Niño 3

Los parámetros definidos para la red son:

Número total de patrones de entrada : 432

Número de patrones de entrenamiento : 70%

Número de patrones de validación y testeo : 30%

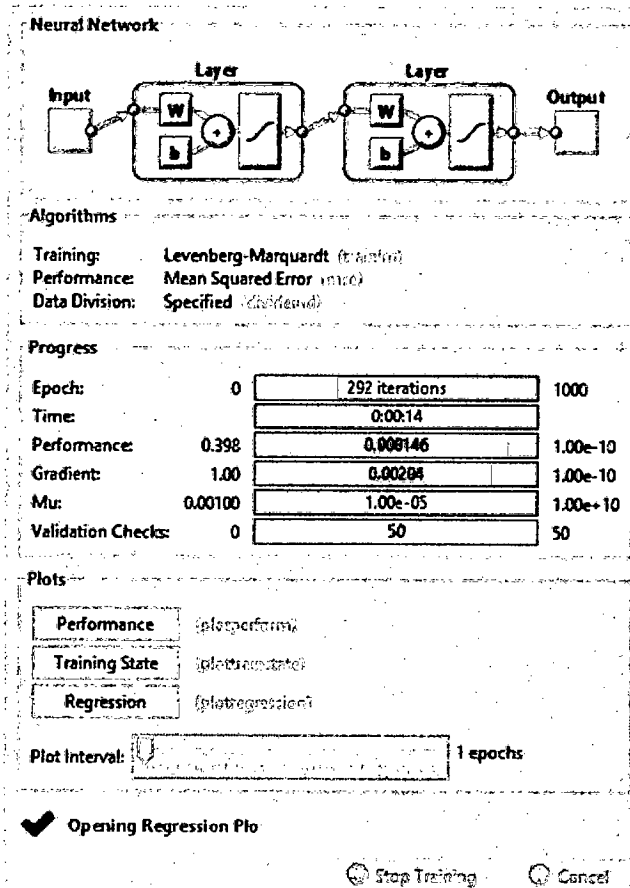
Número de neuronas en la capa de entrada : 12

Número de neuronas en la capa oculta : 25

Número de neuronas en la capa de salida : 1


La función de activación en cada neurona :  $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

Como resultado tenemos:



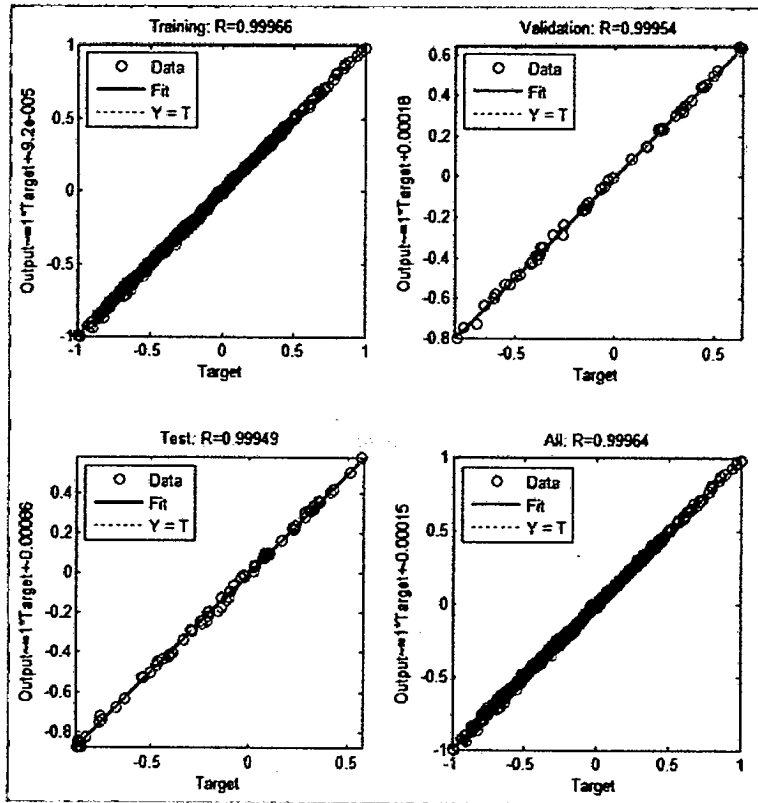
**Figura 4.20: Entrenamiento de rna para tsm niño 3**  
 Fuente: elaboración propia

Como podemos ver en la figura que el proceso de entrenamiento se detuvo en la época 292, esto sucedió porque se completó el número de validaciones.



**Figura 4.21: Aprendizaje de rna para tsm niño 3**  
 Fuente: elaboración propia

La figura 4.21 muestra cómo va disminuyendo el error a través del tiempo hasta alcanzar su valor mínimo durante el entrenamiento.



**Figura 4.22: Ajuste del modelo de rna para tsm niño 3**  
**Fuente: elaboración propia**

Este grafico nos muestra las regresiones entre la salida de la red y los patrones de entrada. Como podemos observar los datos de salida se adecuan bastante bien a los datos de entrenamiento, validación y test; esto se ve reflejado en el valor del coeficiente de correlación general que es 0.99964.

Como resultado obtenemos el cuadro 4.14 con el pronóstico de la tsm en zona niño 3 para el periodo 2016 (enero – junio):

Cuadro 4.14: Pronóstico enero – junio 2016 de tsm niño 3

		Niño 3	Pronóstico RED Niño 3	Error
<b>2016</b>	<b>ENE</b>	28.13	27.83	0.30
	<b>FEB</b>	28.40	27.72	0.68
	<b>MAR</b>	28.69	28.84	-0.15
	<b>ABR</b>	28.63	28.17	0.46
	<b>MAY</b>	27.81	28.30	-0.49
	<b>JUN</b>	26.83	25.43	1.40

Fuente: elaboración propia

Del cuadro anterior, vemos que el pronóstico con redes neuronales artificiales de la tsm en la zona niño 3 se acercan mucho a los valores reales por lo que presenta un error muy pequeño en todos los meses a excepción del mes de junio que es el mes que mayor error presenta (1.40).

#### 4.4.2.3. TSM en Zona Niño 4

Los parámetros definidos para la red son:

Número total de patrones de entrada : 432

Número de patrones de entrenamiento : 70%

Número de patrones de validación y testeo : 30%

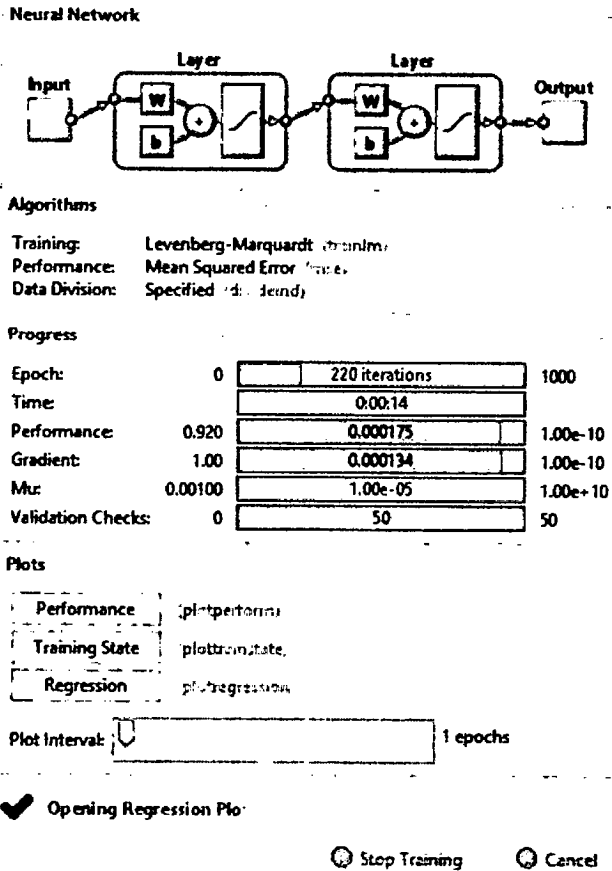
Número de neuronas en la capa de entrada : 12

Número de neuronas en la capa oculta : 25

Número de neuronas en la capa de salida : 1


La función de activación en cada neurona :  $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

Como resultado tenemos:



**Figura 4.23: Entrenamiento de rna para tsm niño 4**  
 Fuente: elaboración propia

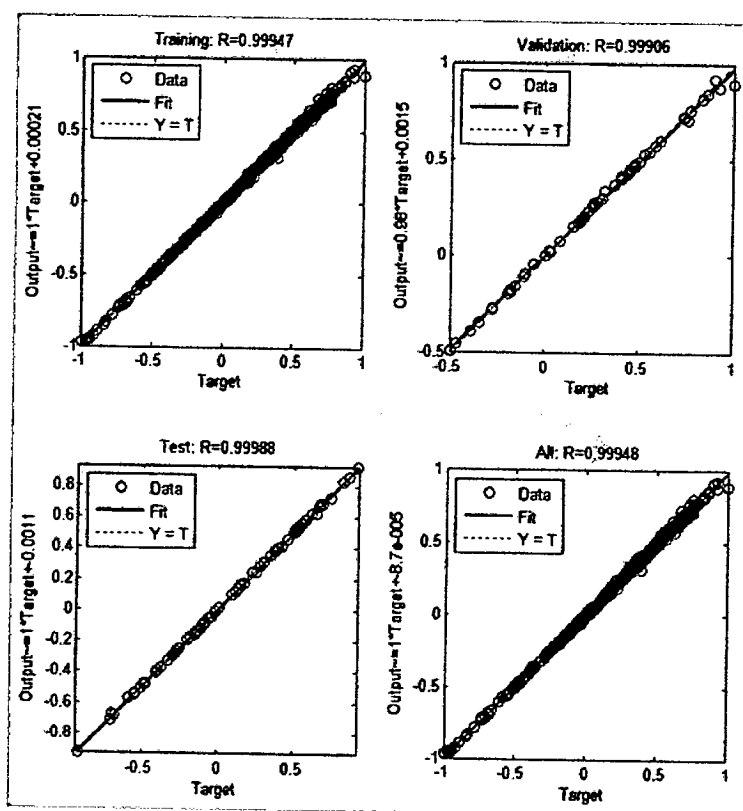
Como podemos ver en la figura que el proceso de entrenamiento se detuvo en la época 220, esto sucedió porque se completó el número de validaciones.



**Figura 4.24: Aprendizaje de rna para tsm niño 4**  
 Fuente: elaboración propia



La figura 4.24 muestra cómo va disminuyendo el error a través del tiempo hasta alcanzar su valor mínimo durante el entrenamiento.



**Figura 4.25: Ajuste del modelo de rna para tsm niño 4**  
Fuente: elaboración propia

Este gráfico nos muestra las regresiones entre la salida de la red y los patrones de entrada. Como podemos observar los datos de salida se adecuan bastante bien a los datos de entrenamiento, validación y test; esto se ve reflejado en el valor del coeficiente de correlación general que es 0.99948.

Como resultado obtenemos el cuadro 4.15 con el pronóstico de la tsm en zona niño 4 para el periodo 2016 (enero – junio):

Cuadro 4.15: Pronóstico enero – junio 2016 de tsm niño 4

		Niño 4	Pronóstico RED Niño 4	Error
2016	ENE	29.46	29.81	-0.35
	FEB	29.40	29.45	-0.05
	MAR	29.42	29.42	0.00
	ABR	29.44	29.48	-0.04
	MAY	29.51	29.54	-0.03
	JUN	29.35	29.56	-0.21

Fuente: elaboración propia

Del cuadro anterior, vemos que el pronóstico con redes neuronales artificiales de la tsm en la zona niño 4 se acercan mucho a los valores reales por lo que presenta un error muy pequeño en todos los meses.

#### 4.4.2.4. TSM en Zona Niño 3.4

Los parámetros definidos para la red son:

Número total de patrones de entrada	: 432
Número de patrones de entrenamiento	: 70%
Número de patrones de validación y testeo	: 30%
Número de neuronas en la capa de entrada	: 12
Número de neuronas en la capa oculta	: 25
Número de neuronas en la capa de salida	: 1

La función de activación en cada neurona :  $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

Como resultado tenemos:

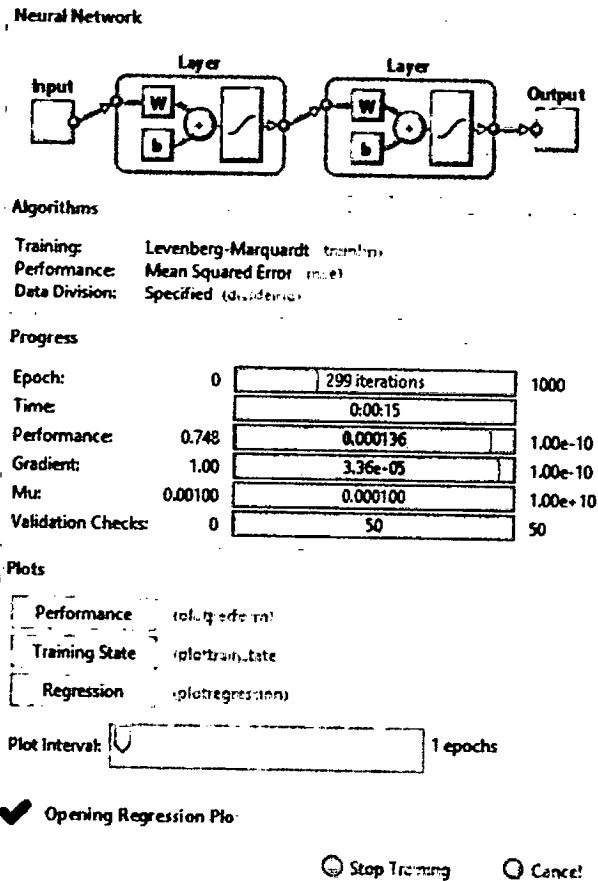


Figura 4.26: Entrenamiento de rna para tsm niño 3.4  
 Fuente: elaboración propia

Como podemos ver en la figura que el proceso de entrenamiento se detuvo en la época 299, esto sucedió porque se completó el número de validaciones.


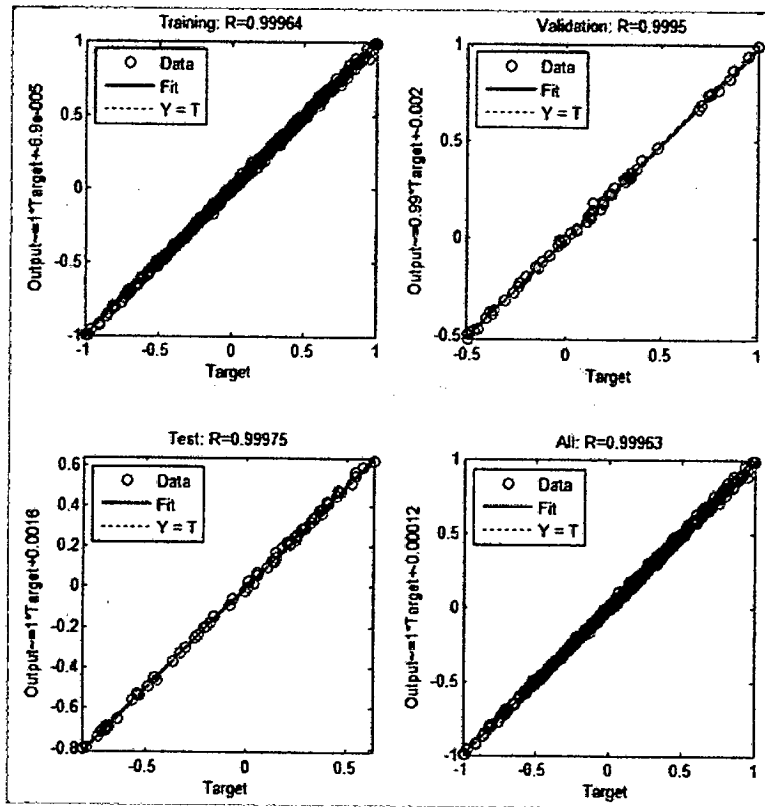


Figura 4.27: Aprendizaje de rna para tsm niño 3.4  
 Fuente: elaboración propia

La figura 4.27 muestra cómo va disminuyendo el error a través del tiempo hasta alcanzar su valor mínimo durante el entrenamiento.



**Figura 4.28: Ajuste del modelo de rna para tsm niño 3.4**  
**Fuente: elaboración propia**

Este gráfico nos muestra las regresiones entre la salida de la red y los patrones de entrada. Como podemos observar los datos de salida se adecuan bastante bien a los datos de entrenamiento, validación y test; esto se ve reflejado en el valor del coeficiente de correlación general que es 0.99963.

Como resultado obtenemos el cuadro 4.16 con el pronóstico de la tsm en zona niño 3.4 para el periodo 2016 (enero – junio):

Cuadro 4.16: Pronóstico enero – junio 2016 de tsm niño 3.4

		Niño 3.4	Pronóstico RED Niño 3.4	Error
2016	ENE	28.95	29.01	-0.06
	FEB	28.90	28.80	0.10
	MAR	28.86	28.96	-0.10
	ABR	28.96	29.01	-0.05
	MAY	28.60	28.85	-0.25
	JUN	27.83	28.65	-0.82

Fuente: elaboración propia

Del cuadro anterior, vemos que el pronóstico con redes neuronales artificiales de la tsm en la zona niño 3.4 se acercan mucho a los valores reales por lo que presenta un error muy pequeño en todos los meses.

#### 4.4.2.5. Velocidad de Vientos Alisios

Los parámetros definidos para la red son:

Número total de patrones de entrada	: 432
Número de patrones de entrenamiento	: 70%
Número de patrones de validación y testeo	: 30%
Número de neuronas en la capa de entrada	: 12
Número de neuronas en la capa oculta	: 24
Número de neuronas en la capa de salida	: 1

La función de activación en cada neurona :  $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

Como resultado tenemos:

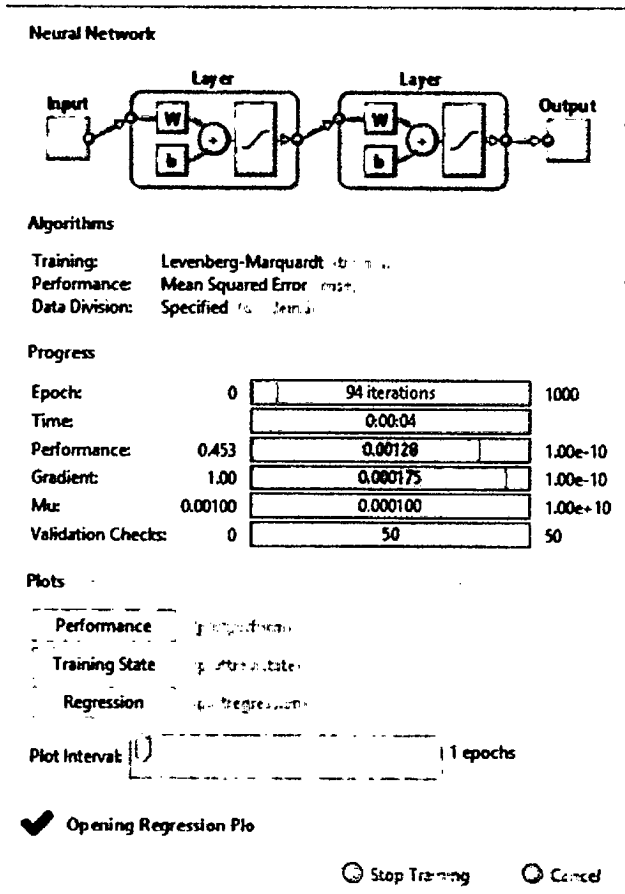


Figura 4.29: Entrenamiento de rna para velocidad de vientos alisios  
Fuente: elaboración propia

Como podemos ver en la figura que el proceso de entrenamiento se detuvo en la época 94, esto sucedió porque se completó el número de validaciones.


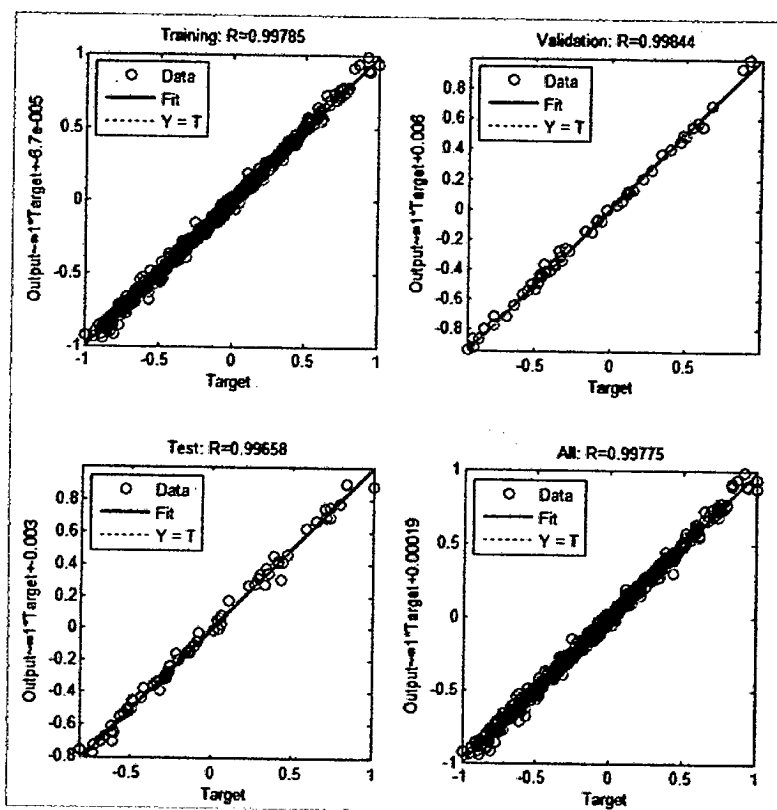


Figura 4.30: Aprendizaje de rna para velocidad de vientos alisios  
Fuente: elaboración propia

La figura 4.30 muestra cómo va disminuyendo el error a través del tiempo hasta alcanzar su valor mínimo durante el entrenamiento.



**Figura 4.31: Ajuste del modelo de rna para velocidad de vientos alisios**  
Fuente: elaboración propia

Este gráfico nos muestra las regresiones entre la salida de la red y los patrones de entrada. Como podemos observar los datos de salida se adecuan bastante bien a los datos de entrenamiento, validación y test; esto se ve reflejado en el valor del coeficiente de correlación general que es 0.99775.

Como resultado obtenemos el cuadro 4.17 con el pronóstico de la velocidad de los vientos alisios para el periodo 2016 (enero – junio):

Cuadro 4.17: Pronóstico enero – junio 2016 de velocidad de los vientos alisios

		Velocidad de Vientos (m/s)	Pronóstico RED Veiloc. Vientos (m/s)	Error
2016	ENE	6.00	6.29	-0.29
	FEB	9.00	7.58	1.42
	MAR	7.80	6.68	1.12
	ABR	2.50	-0.11	2.61
	MAY	1.40	4.32	-2.92
	JUN	0.00	-1.23	1.23

Fuente: elaboración propia

Del cuadro anterior, vemos que el pronóstico con redes neuronales artificiales de la velocidad de los vientos alisios se acerca mucho a los valores reales, sin embargo, existen valores que presentan mayor error como en el caso del mes de mayo.

#### 4.4.3. Diseño de la red neuronal, segunda fase

La red neuronal artificial elegida para modelar el comportamiento de las precipitaciones es el perceptron multicapa en razón a que se conocen los patrones de entrada (variable independiente) que explican la salida es decir las precipitaciones como variable de salida (variable dependiente). Se busca seleccionar el perceptron en función del número de capas ocultas; que modele mejor los datos históricos y pronostique seis meses después del horizonte de planeamiento, las precipitaciones en la ciudad de Piura. De este modo se determinará el modelo predictivo del fenómeno El Niño. Los pesos y bias de las redes neuronales se encuentran en el anexo 8.

#### **Clasificación de datos de entrenamiento, testeo y validación para la RNA**

Los datos de las variables de entrada y salida han sido tomados mensualmente y existen registros de 37 años comprendidos entre 1979 hasta 2015 (444 patrones), por lo cual, el modelo será entrenado con el 70% de los datos, dejando el otro 30%, para la validación y testeo los cuales entrarán a la red escalonados en el rango de -1 y 1; los datos de los meses entre enero – junio del año 2016 se tomarán como muestra para confrontarlos con los valores pronosticados de la red neuronal.



### **Selección de RNA con mejor resultados**

Para realizar la selección de la red neuronal que tenga mejores resultados se ha considerado hacer calibraciones previas con el número de capas ocultas y se determinó que con una capa oculta no se alcanzaba buenos resultados, por lo que se optó usar dos capas ocultas y luego de la calibración se asignaron tres factores de variación, número de neuronas en la primera capa oculta, número de neuronas en la segunda capa oculta y número de épocas, la elección se realizará mediante la evaluación del análisis de varianza y de la comparación de medias de Duncan. Los resultados que se muestran en el cuadro 4.18 que representan el error cuadrático medio de las diferentes corridas del algoritmo de aprendizaje de la red neuronal de acuerdo a los factores indicados, el tiempo de ejecución del algoritmo fue de 120 minutos; el código con el que se ejecuta el algoritmo de aprendizaje y soportado en Matlab se encuentra en el anexo 3.

Factores considerados:

A = Cantidad de neuronas en capa oculta 1: 4, 7, 10

B = Cantidad de neuronas en capa oculta 2: 7, 14, 21

C = Cantidad de épocas: 150, 200, 250

Cuadro 4.18: Evaluación del error cuadrático medio de la rna para precipitaciones

Factores			REPETICIONES				total	Promedio
A	B	C	I	II	III	IV		
4	7	150	0.000143	0.001068	0.003686	0.000196	0.005093	0.001273
4	7	200	0.000143	0.001068	0.000747	0.000195	0.002154	0.000538
4	7	250	0.000143	0.001068	0.000420	0.000195	0.001827	0.000457
4	14	150	0.000080	0.000105	0.000073	0.000098	0.000356	0.000089
4	14	200	0.000061	0.000078	0.000060	0.000063	0.000261	0.000065
4	14	250	0.000056	0.000059	0.000059	0.000061	0.000235	0.000059
4	21	150	0.000062	0.000073	0.001236	0.000296	0.001667	0.000417
4	21	200	0.000034	0.000073	0.001236	0.000051	0.001394	0.000349
4	21	250	0.000034	0.000073	0.000422	0.000043	0.000571	0.000143
7	7	150	0.001688	0.000044	0.000170	0.000077	0.001979	0.000495
7	7	200	0.001120	0.000044	0.000143	0.000077	0.001384	0.000346
7	7	250	0.001117	0.000043	0.000143	0.000077	0.001381	0.000345
7	14	150	0.000073	0.000027	0.000012	0.000066	0.000179	0.000045
7	14	200	0.000018	0.000027	0.000011	0.000036	0.000093	0.000023
7	14	250	0.000017	0.000027	0.000011	0.000036	0.000092	0.000023
7	21	150	0.000021	0.000021	0.000019	0.000043	0.000103	0.000026
7	21	200	0.000021	0.000016	0.000015	0.000022	0.000074	0.000018
7	21	250	0.000021	0.000015	0.000015	0.000018	0.000069	0.000017
10	7	150	0.009772	0.031040	0.000024	0.000022	0.040858	0.010215
10	7	200	0.009167	0.014782	0.000024	0.000011	0.023984	0.005996
10	7	250	0.009167	0.014782	0.000024	0.000010	0.023983	0.005996
10	14	150	0.000007	0.000007	0.000006	0.000015	0.000035	0.000009
10	14	200	0.000005	0.000005	0.000003	0.000006	0.000019	0.000005
10	14	250	0.000004	0.000004	0.000002	0.000003	0.000014	0.000003
10	21	150	0.000007	0.000136	0.000015	0.000004	0.000163	0.000041
10	21	200	0.000003	0.000029	0.000010	0.000002	0.000044	0.000011
10	21	250	0.000003	0.000028	0.000004	0.000002	0.000037	0.000009
<b>TOTAL</b>							<b>0.108046</b>	<b>0.001000</b>

Fuente: elaboración propia

El cuadro 4.18 se pueden observar las diferentes combinaciones de factores con la finalidad de encontrar la mejor combinación, en total se estudiaron 108 redes neuronales y de todas ellas se extrajo el error cuadrático medio.

Cuadro 4.19: Análisis de varianza para tsm Niño 1+2

Factores de variación	gl	SC	CM	Fc	SIG
Tratamientos	26	0.000609			
A	2	0.000119	0.000059	4.926776	**
B	2	0.000185	0.000093	7.694270	**
C	2	0.000009	0.000004	0.360847	
AXB	4	0.000256	0.000064	5.315783	**
AXC	4	0.000008	0.000002	0.173238	
BxC	4	0.000015	0.000004	0.309941	
AXBXC	8	0.000017	0.000002	0.180646	
ERROR	81	0.000974	0.000012		
TOTAL	107	0.001583			
		<b>CV =</b>	<b>1.2022%</b>		

\*. La correlación es significativa en el nivel 0,05

\*\*. La correlación es significativa en el nivel 0,01

Fuente: elaboración propia

El análisis de varianza realizado, muestra que los factores A y B, cantidad de neuronas en la primera capa oculta y cantidad de neuronas en la segunda capa oculta presentan una influencia altamente significativa al 99% en el error cuadrático medio; observándose que el factor número de épocas no tiene diferencias significativas en el error cuadrático medio.

Con respecto a las interacciones se aprecia que la interacción AxB, presentan una influencia altamente significativa estadísticamente al 99%. Sin embargo, el resto de las interacciones no muestran significación en el error cuadrático medio, esto se debe a que el factor C número de épocas no tiene influencia el cálculo del error cuadrático medio de las precipitaciones y la razón es que este factor en los niveles estudiados ya se consiguen errores muy pequeños que ya no hace falta mayor procesamiento computacional; el coeficiente de variabilidad es de 1.2022%.

El análisis de Duncan, en el cuadro 4.20 muestra que con el factor número de neuronas en la primera capa oculta se obtienen mejores resultados en el error cuadrático medio cuando los niveles son 4 y 7 neuronas comportándose estadísticamente iguales, sin embargo, numéricamente con 7 neuronas se consigue el menor error cuadrático medio. Analizando el número de neuronas en la segunda capa oculta se observa que con 14 y 21 neuronas se consiguen

los menores errores cuadráticos siendo estadísticamente iguales, sin embargo, con 14 neuronas en la segunda capa se consigue numéricamente el menor error cuadrático medio llegando a 0.000036; el factor número de épocas todos los niveles se comportan estadísticamente iguales lo que corrobora lo observado en el análisis de varianza, sin embargo numéricamente el menor error cuadrático medio de 0.000784 le corresponde a 250 épocas.

Con respecto a las interacciones se puede afirmar que todas se comportan estadísticamente iguales con excepción de las interacciones 10x7x150, 10x7x200 y 10x7x250 que tienen valores del error cuadrático medio superiores, sin embargo, la interacción que mostró numéricamente un menor error fue 10x14x250 llegando alcanzar un error mínimo de 0.000003.

Cuadro 4.20: Análisis de Duncan a un nivel de significancia de 0.05 y 81 grados de libertad del cuadrado medio del error, de precipitaciones

<b>CLAVE</b>	<b>N° Neuronas ocultas 1</b>	<b>PRECIPITACIONES</b>	
A1	4	0.000377	a
A2	8	0.000149	a
A3	12	0.002476	b
<b>CLAVE</b>	<b>N° Neuronas ocultas 2</b>		
B1	7	0.002851	b
B2	14	0.000036	a
B3	21	0.000114	a
<b>CLAVE</b>	<b>N° Épocas</b>		
C1	150	0.001401	a
C2	200	0.000817	a
C3	250	0.000784	a
<b>CLAVE</b>	<b>Interacción</b>		
A1B1C1	4x7x150	0.001273	a
A1B1C2	4x7x200	0.000538	a
A1B1C3	4x7x250	0.000457	a
A1B2C1	4x14x150	0.000089	a
A1B2C2	4x14x200	0.000065	a
A1B2C3	4x14x250	0.000059	a
A1B3C1	4x21x150	0.000417	a
A1B3C2	4x21x200	0.000349	a
A1B3C3	4x21x250	0.000143	a
A2B1C1	7x7x150	0.000495	a
A2B1C2	7x7x200	0.000346	a
A2B1C3	7x7x250	0.000345	a
A2B2C1	7x14x150	0.000045	a
A2B2C2	7x14x200	0.000023	a
A2B2C3	7x14x250	0.000023	a
A2B3C1	7x21x150	0.000026	a
A2B3C2	7x21x200	0.000018	a
A2B3C3	7x21x250	0.000017	a
A3B1C1	10x7x150	0.010215	b
A3B1C2	10x7x200	0.005996	ab
A3B1C3	10x7x250	0.005996	ab
A3B2C1	10x14x150	0.000009	a
A3B2C2	10x14x200	0.000005	a
A3B2C3	10x14x250	0.000003	a
A3B3C1	10x21x150	0.000041	a
A3B3C2	10x21x200	0.000011	a
A3B3C3	10x21x250	0.000009	a
<b>CV =</b>		<b>1.2022%</b>	

Fuente: elaboración propia

Según el análisis realizado se evidencia y afirma que existen 2 grupos estadísticamente diferente de manera significativa, siendo el de mejor comportamiento la red compuesta de 10 neuronas ocultas en la primera capa, 14 neuronas ocultas en la segunda capa y 250 épocas.

Por lo tanto, teniendo en cuenta los resultados del anterior análisis, se procede a realizar la implementación teniendo los siguientes parámetros:

Neuronas en capa de Entrada: 5

Neuronas en capa oculta 1: 10

Neuronas en capa oculta 2: 14

Neuronas en capa de salida: 1

Función de Transferencia:  $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

Función de Entrenamiento: Levenberg – Marquardt

En la figura 4.32 se muestra el diagrama topológico de la red neuronal elegido para el pronóstico del fenómeno El Niño.




Figura 4.32: Topología rna 5-10-14-1  
Fuente: elaboración propia

#### 4.4.3.1. Creación de la red neuronal

La red que resultó ser seleccionada para modelar y predecir el fenómeno El Niño se muestra a continuación usando como lenguaje de programación Matlab, (ver figura 4.33 y el código del algoritmo en el anexo 3:


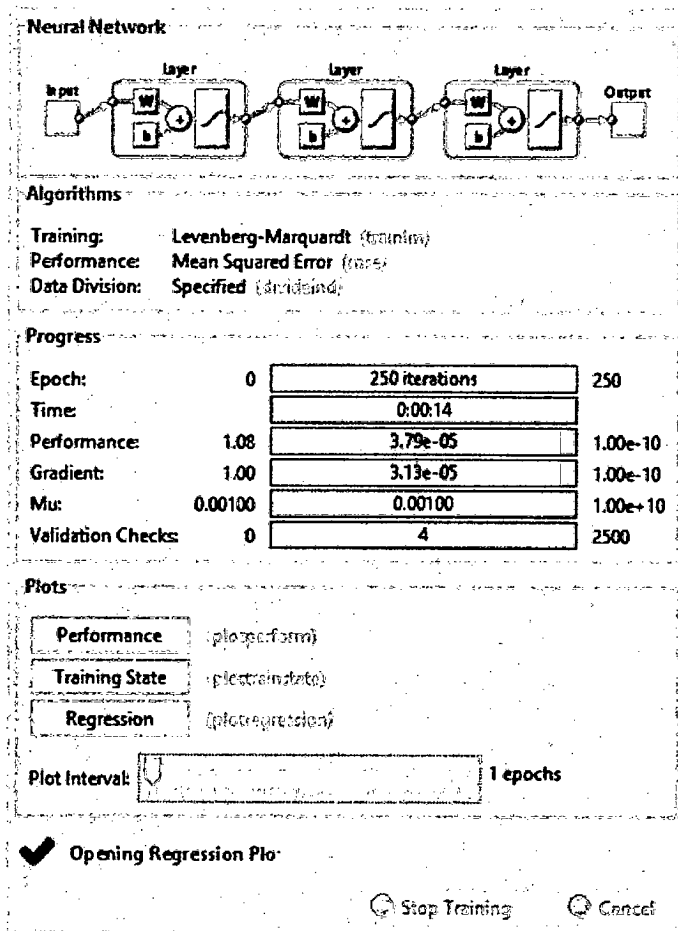


Figura 4.33: Red neuronal  
Fuente: elaboración propia


Haciendo uso del código del software matlab, ver anexo 3, se inicia el entrenamiento de la red neuronal.



**Figura 4.34: Entrenamiento de rna para precipitaciones**  
 Fuente: elaboración propia

La ventana de monitoreo mostrada en la figura 4.34, permite ver en tiempo real la cantidad de épocas, tiempo transcurrido, rendimiento, gradiente de descenso y validaciones realizadas al aprendizaje de la red. Este proceso se detendrá cuando el programa encuentre un valor óptimo de cualquiera de los parámetros antes mencionados. En nuestro caso podemos ver que el proceso de entrenamiento se detuvo cuando el número de épocas ha llegado a 250.

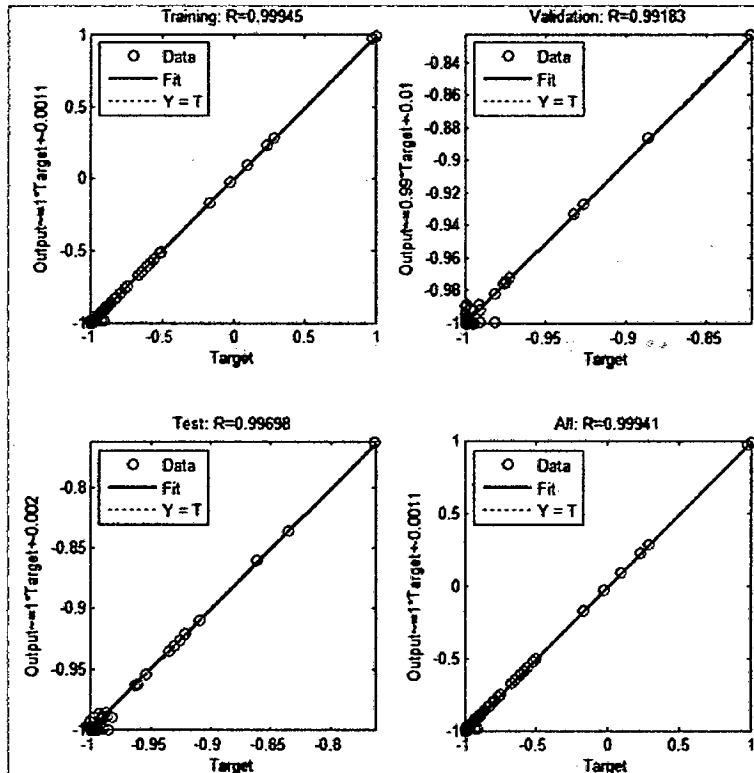




**Figura 4.35: Aprendizaje de rna para precipitaciones**  
**Fuente: elaboración propia**

De la figura 4.35 podemos observar que el error cuadrático medio empieza con un valor grande y luego muestra una tendencia decreciente, hasta lograr un valor mínimo en la 250va iteración, lo que demuestra que la red está aprendiendo; en este punto podemos ver que el error es muy pequeño.

Es necesario aclarar que el error cuadrático medio que se observa sobre la parte superior de la figura 4.30, esto es 0.000012787 corresponde al error cuadrático medio de los datos de prueba línea de color verde, estos datos se utilizan únicamente para probar la red neuronal, los datos que se muestran en el cuadro 4.18, corresponden al error cuadrático medio de todos los datos de entrenamiento.



**Figura 4.36: Ajuste del modelo de rna para precipitaciones**  
**Fuente: elaboración propia**

La figura 4.36 nos muestra las regresiones entre la salida de la red y los patrones de entrada. Como podemos observar los datos de salida se adecuan bastante bien a los datos de entrenamiento, validación y test; esto se ve reflejado en el valor del coeficiente de correlación general que es 0.99941.

#### 4.4.4. Pronóstico Fenómeno El Niño

Cuando la red se ha entrenado y se ha obtenido un rendimiento adecuado (error de entrenamiento mínimo) se procede a hacer el pronóstico utilizando los valores obtenidos de las redes neuronales de las variables independientes, con las cuales se crean arreglos de tal manera que la red los pueda leer e interpretar y de esa forma realice un adecuado pronóstico.

Como resultado obtenemos el cuadro 4.21 con el pronóstico de las precipitaciones para el periodo 2016 (enero – junio):

Cuadro 4.21: Pronóstico enero – junio 2016 de las precipitaciones

		Precipitación Real	Pronóstico RED Precipitación	Error
2016	ENE	0.80	0.0058	0.7942
	FEB	52.00	23.3900	28.6100
	MAR	82.00	95.6170	-13.6170
	ABR	0.00	0.3731	-0.3731
	MAY	0.00	0.0086	-0.0086
	JUN	0.00	0.0976	-0.0976

Fuente: elaboración propia

Del cuadro anterior, vemos que los pronósticos con redes neuronales artificiales de las precipitaciones acercan mucho a los valores reales, siendo en mayor error el mes de febrero (28.61 mm) sin embargo, en los otros meses el pronóstico se ajusta muy bien siendo mejor que el realizado con el método de Winters.


#### 4.5. Análisis y comparación de resultados de los modelos

Como se ha podido observar, se han desarrollado dos metodologías para el pronóstico de las precipitaciones producidas por el Fenómeno El Niño en Piura, el método de Winters y de redes neuronales artificiales, obteniendo resultados aceptables.

En este apartado, se compararán los resultados obtenidos en ambos modelos y se seleccionará el que tenga mejores medidas de exactitud, de igual manera se elegirá el que realice el mejor pronóstico.


##### 4.5.1. Contraste de resultados

En la figura 4.32 se hace una comparación entre los resultados obtenidos por medio del modelo de Winters y los valores reales de las precipitaciones, con el cual podemos comprobar que existen valores que no han podido ser reproducidos con exactitud por este método.




**Figura 4.37: Comparativo de los valores reales de precipitaciones y los obtenidos con Winters**  
**Fuente: elaboración propia**

El caso de los valores obtenidos mediante redes neuronales artificiales es muy diferente, en la figura 4.37 podemos observar que estos valores modelan un alto porcentaje de observaciones de precipitaciones.



**Figura 4.38: Comparativo de los valores reales de precipitaciones y los obtenidos con rna**  
**Fuente: elaboración propia**

Cuando realizamos una ampliación a la figura 4.38, podemos observar que no todos los valores son pronosticados por la red neuronal, pero si en su mayoría y con un error menor que el del método de Winters. ver figura 4.39.



**Figura 4.39: Ampliación de gráfica comparativa precipitaciones reales - pronóstico rna**  
**Fuente: elaboración propia**

En el siguiente cuadro se muestran los valores de los errores de ambos modelos:

**Cuadro 4.22: Comparativo de ECM, RECM y MAPE de los modelos de precipitaciones**

<b>TECNICA</b>	<b>ECM</b>	<b>RECM</b>	<b>MAPE</b>
<b>Winters</b>	$1.2600 \times 10^{-2}$	0.1124	9.4641%
<b>RNA</b>	$3.7909 \times 10^{-5}$	0.0062	0.2492%

Fuente: elaboración propia

En el cuadro 4.22, se muestran los errores ECM, RCM y MAPE, como podemos apreciar es muy amplia la diferencia entre ambos modelos, mientras el ECM de Winters es  $1.26 \times 10^{-2}$ , con la red obtenemos un valor muy pequeño,  $3.7909 \times 10^{-5}$ , lo mismo pasa con el RECM y el MAPE, con lo cual podemos decir que el modelo de redes neuronales artificiales presenta un mejor ajuste al comportamiento de las precipitaciones provocadas por el Fenómeno El Niño en Piura.

#### 4.5.2. Análisis del pronóstico

En el siguiente cuadro se muestran los valores de los errores del pronóstico de ambos modelos:

Cuadro 4.23: Comparativo normalizado de ECM, RECM y MAPE del pronóstico de los modelos

		Precipitación Real	Pronóstico RED Precipitación	ECM	MAPE	Pronóstico WINTERS Precipitación	ECM	MAPE
2016	ENERO	0.8	0.0058	0.0000	0.20%	0.0000	4.23E-06	0.21%
	FEBRERO	52	23.3900	0.0054	8.48%	0.3561	0.0176	15.32%
	MARZO	82	95.6170	0.0012	4.43%	80.4059	1.68E-05	0.52%
	ABRIL	0	0.3731	0.0000	0.10%	57.2984	0.0217	14.72%
	MAYO	0	0.0086	0.0000	0.00%	18.2448	0.0022	4.69%
	JUNIO	0	0.0976	0.0000	0.03%	7.9373	4.16E-04	2.04%
		<b>Promedio</b>	<b>0.0011</b>	<b>2.21%</b>	<b>Promedio</b>	<b>0.0070</b>	<b>6.25%</b>	
		<b>RECM</b>	<b>0.0332</b>		<b>RECM</b>	<b>0.0836</b>		

Fuente: elaboración propia

En la siguiente gráfica se muestran los valores reales de las precipitaciones de los meses entre enero – junio del 2016 y los pronósticos obtenidos con ambos métodos.




Figura 4.40: Gráfica de valores de pronóstico de precipitaciones (mm) para meses enero – junio 2016  
Fuente: elaboración propia

En el análisis comparativo que se muestra en el cuadro 4.23 y la figura 4.40 observamos que los pronósticos de las precipitaciones no son exactos al comparar lo real con lo pronosticado por la red, sin embargo, no cabe duda que los pronósticos de la red neuronal son mucho más precisos.

Finalmente podemos decir que después del diseño y análisis de los métodos de Winters y redes neuronales para las precipitaciones en Piura, ha quedado demostrado que las redes neuronales muestran un mejor resultado por lo cual podemos decir que se ha podido predecir satisfactoriamente el Fenómeno El Niño con seis meses de anticipación a la presencia del mismo. El estudio muestra que las redes neuronales son una técnica altamente confiable para primero encontrar un patrón de comportamiento de las precipitaciones y luego predecir el fenómeno.

## CONCLUSIONES

- 1) El comportamiento de las variables es simétrico, manteniendo una desviación estándar pequeña, excepto en la precipitación y los vientos alisios que tiene un comportamiento asimétrico. Con la correlación de Pearson se pudo confirmar que las variables temperatura superficial de mar en las zonas denominadas Niño 1+2, Niño 3 y Niño 3.4 se encuentran correlacionadas con un nivel de confianza de 0.01 y la velocidad de vientos a un 0,05, esto con relación a las precipitaciones en Piura. La variable Niño 4 no muestra significancia estadística, sin embargo, se decidió incluirla en el modelo debido a que forma parte de la zona en la que se desarrolla el fenómeno El Niño.
- 2) El análisis de la serie meteorológica reveló que los datos de las precipitaciones en Piura no presentan los componentes de tendencia ni estacionalidad. Esto se explica por el hecho de que el fenómeno en estudio es errático. Por lo tanto, se trabajó el modelo matemático de Winters los componentes de tendencia y estacionalidad iguales a cero, obteniendo un error cuadrático medio de modelo de 0.0126 y un MAPE de 9.4641%.
- 3) La topología de la red que mejor responde al modelamiento y pronóstico del Fenómeno El Niño, fue aquella que estaba compuesta por 10 neuronas en la capa oculta, 14 neuronas en la segunda capa oculta y 250 épocas. Obteniendo un ECM de  $3.7909 \times 10^{-5}$  y un MAPE de 0.2492% para el modelamiento y para el pronóstico se obtuvo un ECM de 0.0011 y un MAPE de 2.21%.
- 4) Fue necesario probar varias combinaciones para encontrar una topología que responda mejor los datos de precipitación del Fenómeno El Niño. Los factores que se tomaron en cuenta fueron cantidad de neuronas en la primera capa oculta (4, 7, 10), cantidad de neuronas en la segunda capa oculta (7, 14, 21) y cantidad de épocas (150, 200, 250). Esto se hizo porque no existe una regla con la cual se pueda determinar el diseño de un determinado problema. Quedando elegida aquella red que está compuesta por 10 neuronas en la primera capa oculta, 14 en la segunda capa oculta y 250 épocas.



- 5) La metodología que mejor precisión alcanzó las predicciones de las precipitaciones de Piura provocadas por el fenómeno El Niño fue la de redes neuronales artificiales la cual obtuvo un error cuadrático medio de 0.0011 y un MAPE de 2.21% frente a los obtenidos de con el método de Winter, con un error cuadrático medio de 0.0070 y un MAPE de 6.25%.
- 6) El pronóstico del Fenómeno El Niño para Piura que se realizó en el periodo enero a junio del 2016 dio como resultado que las precipitaciones se mantienen en un rango muy bajo, por lo que se descarta la presencia del fenómeno El Niño.

## RECOMENDACIONES

- 1) Para los que deseen realizar un estudio general de toda la región, hacer una evaluación más detallada, tomando todas las estaciones meteorológicas que se encuentran en todo el departamento de Piura, para obtener un informe sectorizado de las precipitaciones por provincias o distritos.
- 2) Se debe hacer una clasificación para determinar una escala de la intensidad del Fenómeno El Niño, de tal manera que no se incurra en errores al tomar como referencia las alertas de organismos internacionales.
- 3) Para las personas que deseen seguir con la investigación, probar con otros algoritmos de entrenamiento con la finalidad de mejorar el rendimiento de la red.
- 4) A la comunidad científica difundir el uso de las redes neuronales artificiales de tal manera que se apliquen en otros temas de interés.
- 5) Finalmente podemos decir que para hacer uso de las redes neuronales artificiales se necesita llevar a cabo un tratamiento muy detallado, ya que estas tienen la capacidad de aprender y reproducir patrones de comportamiento de sistemas sin usar un modelo evidente y no son capaces de identificar si los patrones ingresados presentan errores por lo que es necesario siempre hacer pre procesamiento de la información como en este estudio fue necesario hacer un escalamiento de los datos entre -1 y 1.

## BIBLIOGRAFIA

- Albadas, E (2012). Introducción al reconocimiento de patrones mediante redes neuronales. Universidad Politécnica de Catalunya. España.
- Arellano, M. (2001). Introducción al Análisis Clásico de Series de Tiempo, Recuperado de <http://www.5campus.com/leccion/seriest>
- Arenas, J (2009). Desarrollo De Un Modelo De Pronóstico De Caudales Semanales Asociado A La Variabilidad Climática Interanual En Colombia. (Tesis de Maestría). Universidad Nacional de Colombia. Medellín, Colombia. Recuperado de <http://www.bdigital.unal.edu.co/2029/1/98668319.2010.pdf>
- Ataurina, M. (2013). Matlab y Simulink Para Ingeniería. Universidad de Ciencias y Humanidades. Lima, Perú.
- Banco Central De Reserva Del Perú (2014). Caracterización del Departamento de Piura. Piura. Perú.
- Basogain, X. (1998). Redes Neuronales Artificiales y Sus Aplicaciones. Recuperado de <http://cvb.ehu.es/>
- Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres. (2012). Escenarios de Riesgos Ante la Probabilidad de Ocurrencia del Fenómeno El Niño. CENEPRED. Perú
- Climate Center. Índices. NOAA. Recuperado de: <http://www.cpc.ncep.noaa.gov/data>.
- Corporación Andina de Fomento. (2000). Las Lecciones del Niño. El Fenómeno El Niño 1997 – 1998 memorias, retos y soluciones. CAF. Perú.
- Comunidad Andina. (2009). Atlas De Las Dinámicas Del Territorio Andino: Población Y Bienes Expuestos A Amenazas Naturales. Cali, Colombia.
- El Clima. Fenómeno El Niño. México. Recuperado de [http://www.elclima.com.mx/fenomeno\\_el\\_nino.htm](http://www.elclima.com.mx/fenomeno_el_nino.htm)

- Facho, W. (2012). Región Piura. Recuperado de <http://saboresinperu.blogspot.pe/2012/08/piura.html>
- Ferradas, P. (2000). El Fenómeno "El Niño" y los desastres: Enfoque y estrategias de las ONGs. Lima. Perú.
- Fernández, J (2003). Técnicas Cuantitativas Elementales De Previsión Univariante. Madrid, España.
- Flores, E. (2010). Mapa del Perú, descripción de sus departamentos. Recuperado de <http://edenson.es.tl/19-.Piura.htm>
- García, J.; Gonzales, J. y Jornet, J. (2010). SPSS: Pruebas No Paramétricas. innovaMIDE, Universitat de Valencia. España.
- Hilera, J. y Martínez, V. (1995). Redes neuronales artificiales. Fundamentos, modelos y aplicaciones. Editorial Rama. Madrid. España.
- Instituto Oceanográfico de la Armada (2011). El Niño: Generalidades. Ecuador. Recuperado de [http://www.inocar.mil.ec/modelamiento/elnino/nino\\_generalidades.php](http://www.inocar.mil.ec/modelamiento/elnino/nino_generalidades.php)
- Instituto Geofísico del Perú. (2014). Generación de Modelos Climáticos Para el Pronóstico de Ocurrencia del Fenómeno El Niño. Vol. 1. Lima, Perú.
- Izaurieta, F. & Saavedra, C. Redes Neuronales Artificiales. Universidad de Concepción, Concepción, Chile.
- Jiménez, M. (2009). Modelamiento Del Pronóstico De Demanda Basado En El Enfoque De Series De Tiempo, Utilizando Redes Neuronales. Universidad Nacional De Piura – Perú.
- Forge, D. (2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. Universidad Tecnológica Nacional. Rosario, Argentina.

- Laqui, W. (2010). Aplicación De Redes Neuronales Artificiales A La Modelización Y Previsión De Caudales Medios Mensuales Del Rio Huancané. Perú. Revista Peruana Geo-Atmosférica RPGA
- Martínez, V. (2008). Desarrollo de sistemas físicos para implantar modelos de computación con membranas (Tesis Doctoral). Universidad Politécnica de Madrid. España. Recuperado de <http://oa.upm.es/1168/>
- Matallanas, E. (2014). Redes neuronales artificiales: introducción y aplicaciones. Universidad Politécnica de Madrid. España. Recuperado de <http://es.slideshare.net/matallanas/irin-clase140509>
- Maturana, J, Bello, M y Manley, M (2004). Antecedentes históricos y descripción del fenómeno El Niño, Oscilación del Sur. Servicio Hidrográfico y Oceanográfico de la Armada de Chile. Chile.
- Meschino, G (2006). Redes Neuronales en Matlab. Recuperado de <http://www3.fi.mdp.edu.ar/meschino/Presentaciones/GUSTAVO%2007%20-%20REDES%20NEURONALES%20MATLAB.pdf>
- Minitab (2016). Series de tiempo. Soporte Minitab. Recuperado de <http://support.minitab.com/es-mx/minitab/17/topic-library/modeling-statistics/time-series/time-series-models/what-are-mape-mad-and-msd/>.
- Montgomery, D. (1991). Diseño y Análisis De Experimentos. Ed. Grupo Editorial Iberoamérica.
- Neural Network Toolbox. (2007). Recuperado de [www.varpa.es/Docencia/Files/Curso08/boletin3.pdf](http://www.varpa.es/Docencia/Files/Curso08/boletin3.pdf)
- NOAA. Recuperado de [http://www.pmel.noaa.gov/el\\_nino/](http://www.pmel.noaa.gov/el_nino/)
- Oficina de Gestión de la Información y Estadística. (2015). Carpeta Georeferencial Región Piura. Congreso de la Republica. Lima. Perú.
- Once, P. (2010). Inteligencia Artificial con Aplicaciones a la Ingeniería. Mexico. Editorial AlphaOmega

- Programa de las Naciones Unidas para el Desarrollo (2013). Informe sobre Desarrollo Humano Perú 2013. Cambio climático y territorio: Desafíos y respuestas para un futuro sostenible. PNUD.
- Ramírez, R. Zambrano, E y Garcés, J. (2000). Predicción Del Evento El Niño 97-98 En El Mar Ecuatoriano Usando Métodos Estadísticos. Acta Oceanográfica del Pacífico. INOCAR. Ecuador.
- Rosa, J. (2013). Redes Neuronales Artificiales [Mensaje en un Blog]. Recuperado de <http://aprendiendoatravesderedes.blogspot.com/>
- Sánchez, R. (2002). Un Modelo De Series Temporales Para El Fenómeno El Niño (Tesis De Grado). Escuela Superior Politécnica Del Litoral. Guayaquil. – Ecuador
- Sánchez, S. (2014). Departamento de Piura [Mensaje en un Blog]. Recuperado de <http://alexasv96.blogspot.com/2014/08/departamento-de-piura.html>
- S. Makridakis, S.C. Wheelwright and R.J. Hyndman. Forecasting: Methods and Applications. John Wiley & Sons, 1998.
- Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI), (2014). El Fenómeno El Niño en el Perú. SENAMHI. Lima, Perú.

## ANEXOS

### ANEXO 1

#### PROMEDIO MENSUAL DE VARIABLES

MES	Precipitaciones (mm)	TSM Niño 1+2 (°C)	TSM Niño 3 (°C)	TSM Niño 4 (°C)	TSM Niño 3.4 (°C)	Velocidad de Vientos (m/s)
ENERO	29.83	24.6	25.65	26.55	28.22	15.54
FEBRERO	31.01	26.04	26.39	26.73	28.12	14.51
MARZO	50.4	26.43	27.17	27.23	28.24	11.39
ABRIL	21.66	25.62	27.51	27.72	28.51	8.26
MAYO	10.21	24.44	27.19	27.86	28.81	5.01
JUNIO	4.52	23.15	26.56	27.64	28.82	2.06
JULIO	0.2	22.04	25.78	27.24	28.75	-0.28
AGOSTO	0.06	21.07	25.19	26.88	28.66	-3.14
SEPTIEMBRE	0.13	20.78	25.04	26.81	28.67	-3.03
OCTUBRE	0.63	21.05	25.08	26.79	28.68	1.65
NOVIEMBRE	1.28	21.95	25.18	26.76	28.64	8.07
DICIEMBRE	6.17	22.96	25.33	26.7	28.51	13.36

Fuente: elaboración propia

Los valores mostrados en el cuadro anterior representan los promedios mensuales de las variables involucradas en el estudio, obtenidos del periodo enero 1979 – diciembre 2015, los datos se encuentran en el anexo 4 y han sido tomados de diferentes fuentes, los datos de la tsm de todas las zonas y la velocidad de los vientos se obtuvieron de la página web de la NOAA ([www.cpc.ncep.noaa.gov/data](http://www.cpc.ncep.noaa.gov/data)) mientras que los datos de las precipitaciones han sido proporcionados por el Proyecto Especial Chira Piura.

## ANEXO 2

### ANÁLISIS DE ERROR CUADRÁTICO MEDIO Y ANÁLISIS DE VARIANZA

En los siguientes apartados se muestran los cuadros con el error cuadrático medio de las repeticiones de las redes neuronales con las diferentes combinaciones de factores, además se muestra el cuadro que contiene el análisis de varianza para cada variable, para poder hacer la elección de la mejor red.

Se dice que la muestra es significativa cuando el p-valor (probabilidad que mide la evidencia en contra de la hipótesis nula) está por debajo de 5% (0.05) y altamente significativa cuando está por debajo del 1% (0.01); en este caso no se muestra el p-valor, solo se muestra un asterisco si es significativo o dos asteriscos si es altamente significativo.

#### 2.a. Temperatura superficial del mar zona Niño 1+2

Factores:

A = Cantidad de retardos: 4, 8, 12

B = Cantidad de neuronas en capa oculta: 5, 15, 25

Evaluación del error cuadrático medio de la rna para tsm Niño 1+2

Factores		REPETICIONES				Total	Promedio
A	B	I	II	III	IV		
4	5	0.04898	0.04909	0.04899	0.04899	0.19605	0.04901
4	15	0.04682	0.04729	0.04628	0.04776	0.18816	0.04704
4	25	0.04712	0.04656	0.04534	0.04418	0.18320	0.04580
8	5	0.00734	0.00734	0.01072	0.00797	0.03337	0.00834
8	15	0.00750	0.00739	0.00710	0.00662	0.02862	0.00715
8	25	0.00655	0.00581	0.00540	0.00597	0.02373	0.00593
12	5	0.03844	0.00695	0.00729	0.01102	0.06370	0.01592
12	15	0.00573	0.00555	0.00567	0.00548	0.02243	0.00561
12	25	0.00423	0.00479	0.00600	0.00561	0.02063	0.00516
<b>TOTAL</b>						<b>0.75989</b>	<b>0.02111</b>

Fuente: elaboración propia



Análisis de varianza para tsm Niño 1+2

Factores de variación	Grados de libertad	Suma cuadrados	Cuadrados Medios	Fc	SIG
Tratamientos	8	0.01268			
A	2	0.01235	0.00618	237.11148	**
B	2	0.00020	0.00010	3.91369	*
AXB	4	0.00013	0.00003	1.20443	
ERROR	27	0.00070	0.00003		
TOTAL	35	0.01338			
		CV =	0.1234%		

\*. La correlación es significativa en el nivel 0,05

\*\*.. La correlación es significativa en el nivel 0,01

Fuente: elaboración propia

2.b. Temperatura superficial del mar zona Niño 3

Factores:

A = Cantidad de retardos: 4, 8, 12

B = Cantidad de neuronas en capa oculta: 5, 15, 25

Evaluación del error cuadrático medio de la rna para tsm Niño 3

Factores		REPETICIONES				Total	Promedio
A	B	I	II	III	IV		
4	5	0.038310	0.037435	0.037385	0.037357	0.150487	0.037622
4	15	0.038100	0.038057	0.037037	0.037358	0.150552	0.037638
4	25	0.035430	0.038072	0.042931	0.035111	0.151544	0.037886
8	5	0.009740	0.010511	0.009948	0.010023	0.040223	0.010056
8	15	0.009108	0.008442	0.007533	0.009384	0.034467	0.008617
8	25	0.008174	0.007373	0.008381	0.007566	0.031494	0.007874
12	5	0.008935	0.008334	0.008823	0.026648	0.052740	0.013185
12	15	0.007600	0.008062	0.007211	0.006820	0.029693	0.007423
12	25	0.005874	0.004883	0.006395	0.004541	0.021693	0.005423
TOTAL						0.662894	0.018414

Análisis de varianza para tsm Niño 3

Factores de variación	gl	SC	CM	Fc	SIG
Tratamientos	8	0.006846			
A	2	0.006706	0.003353	313.597567	**
B	2	0.000067	0.000034	3.149452	
AXB	4	0.000073	0.000018	1.697374	
ERROR	27	0.000289	0.000011		
TOTAL	35	0.007135			
			CV =	0.0581%	

\*. La correlación es significativa en el nivel 0,05

\*\* . La correlación es significativa en el nivel 0,01

Fuente: elaboración propia

2.c. Temperatura superficial del mar zona Niño 4

Factores:

A = Cantidad de retardos: 4, 8, 12

B = Cantidad de neuronas en capa oculta: 5, 15, 25

Evaluación del error cuadrático medio de la rna para tsm Niño 4

Factores		REPETICIONES				Total	Promedio	
A	B	I	II	III	IV			
4	5	0.018352	0.018378	0.018317	0.018091	0.073138	0.018284	
4	15	0.016884	0.016940	0.017303	0.016555	0.067683	0.016921	
4	25	0.016132	0.016687	0.016349	0.016132	0.065300	0.016325	
8	5	0.011933	0.011814	0.011926	0.011912	0.047584	0.011896	
8	15	0.010656	0.010296	0.010334	0.010472	0.041757	0.010439	
8	25	0.009309	0.011891	0.009845	0.010490	0.041536	0.010384	
12	5	0.011703	0.011678	0.011491	0.012330	0.047202	0.011800	
12	15	0.008654	0.008779	0.011101	0.009583	0.038117	0.009529	
12	25	0.007522	0.010474	0.009925	0.010229	0.038150	0.009538	
						TOTAL	0.460466	0.012791

### Análisis de varianza para tsm Niño 4

Factores de variación	gl	SC	CM	Fc	SIG
Tratamientos	8	0.0003762			
A	2	0.000349	0.000174	333.089554	**
B	2	0.000026	0.000013	25.153615	**
AXB	4	0.000001	0.000000	0.639650	
ERROR	27	0.000014	0.000001		
TOTAL	35	3.90331E-04			
		CV =	0.0041%		

\*. La correlación es significativa en el nivel 0,05

\*\* . La correlación es significativa en el nivel 0,01

Fuente: elaboración propia

### 2.d. Temperatura superficial del mar zona Niño 3.4

Factores:

A = Cantidad de retardos: 4, 8, 12

B = Cantidad de neuronas en capa oculta: 5, 15, 25

### Evaluación del error cuadrático medio de la rna para tsm Niño 3.4

Factores		REPETICIONES				Total	Promedio
A	B	I	II	III	IV		
4	5	0.026403	0.026718	0.026678	0.027357	0.107156	0.026789
4	15	0.026212	0.023327	0.025141	0.025906	0.100585	0.025146
4	25	0.023522	0.022484	0.022840	0.022640	0.091486	0.022872
8	5	0.013356	0.013506	0.014093	0.013044	0.053999	0.013500
8	15	0.022250	0.011792	0.012537	0.012192	0.058771	0.014693
8	25	0.010442	0.011928	0.011302	0.010775	0.044446	0.011112
12	5	0.011179	0.013072	0.013048	0.014323	0.051622	0.012906
12	15	0.008394	0.010870	0.009265	0.010011	0.038540	0.009635
12	25	0.008264	0.007291	0.008134	0.007890	0.031579	0.007895
					TOTAL	0.578186	0.016061

Análisis de varianza para tsm Niño 3.4

Factores de variación	gl	SC	CM	Fc	SIG
Tratamientos	8	0.001580			
A	2	0.001470	0.000735	212.611866	**
B	2	0.000089	0.000044	12.828766	**
AXB	4	0.000021	0.000005	1.491440	
ERROR	27	0.000093	0.000003		
TOTAL	35	0.001673			
		CV =	0.0215%		

\*. La correlación es significativa en el nivel 0,05

\*\* . La correlación es significativa en el nivel 0,01

Fuente: elaboración propia

2.e. Velocidad de vientos alisios

Factores:

A = Cantidad de retardos: 4, 8, 12

B = Cantidad de neuronas en capa oculta: 5, 15, 25

Evaluación del error cuadrático medio de la rna para velocidad de vientos alisios

Factores		REPETICIONES				Total	Promedio
A	B	I	II	III	IV		
4	8	0.073896	0.073552	0.073673	0.074252	0.295374	0.073844
4	16	0.068653	0.069394	0.071605	0.069632	0.279284	0.069821
4	24	0.080677	0.069379	0.063895	0.078304	0.292255	0.073064
8	8	0.064868	0.064170	0.066138	0.066327	0.261503	0.065376
8	16	0.053678	0.060867	0.060790	0.061282	0.236617	0.059154
8	24	0.056410	0.051656	0.051985	0.049453	0.209504	0.052376
12	8	0.047659	0.049706	0.067928	0.048449	0.213744	0.053436
12	16	0.036541	0.033796	0.040736	0.040627	0.151701	0.037925
12	24	0.033863	0.031371	0.031690	0.033714	0.130639	0.032660
TOTAL						2.070621	0.057517

Análisis de varianza para velocidad de vientos alisios

Factores de variación	gl	SC	CM	Fc	SIG
Tratamientos	8	0.007076			
A	2	0.005768	0.002884	134.613022	**
B	2	0.000860	0.000430	20.070096	**
AXB	4	0.000448	0.000112	5.227229	**
ERROR	27	0.000578	0.000021		
TOTAL	35	0.007654			
		CV =	0.0372%		

\*. La correlación es significativa en el nivel 0,05

\*\* . La correlación es significativa en el nivel 0,01

Fuente: elaboración propia

## ANEXO 3

### CODIGO MATLAB

#### 3.a. Código red de precipitaciones

```
%TESIS - MODELAMIENTO DEL FENÓMENO EL NIÑO EN PIURA APLICANDO REDES
NEURONALES ARTIFICIALES
x=xlsread('data 3.xlsx');
N=[];[n,l]=size(x);
for s=2:l;
    j=1;
    for i=1:n
        N(s-1,j)=x(i,s);
        j=j+1;
    end
end
h= x(1:444, 1);
Inputs=N;
Targets= h';
[PN,ps]=mapminmax(Inputs);
[TN,ts]=mapminmax(Targets);
net = newff(PN, TN, [10 14], {'tansig', 'tansig'}, 'trainlm');
net.trainParam.epochs = 250;
net.trainParam.max_fail= 2500;
net.trainParam.goal = 0.0000000001;
%DIVISIÓN DE DATOS
valset.P=PN(:,313:378);
valset.T=TN(:,313:378);
testset.P = PN(:, 379:n);
testset.T = TN(:, 379:n);
%ERROR CUADRÁTICO MEDIO
net.performFcn = 'mse';
%ENTRENAMIENTO DE LA RNA
[net, tr] = train(net, PN, TN, [], [], testset, valset);
output = sim(net, PN);
[Salida] = mapminmax('reverse', output, ts);
%GRÁFICA
plot (Targets, 'ob')
hold on
plot(Salida, '+r')
%PESOS Y BIAS POR CADA CAPA
W1c = net.iw{1,1} ; % iw: Capa de entrada
W2c = net.lw{2,1} ; % lw: Segunda Capa
W3c = net.lw{3,2} ; % lw: tercera Capa
B1c = net.b{1} ; %bias 1ra capa
B2c = net.b{2} ; %bias 2da capa
B3c = net.b{3} ; %bias 3ra capa
%PRONÓSTICO
NAR = xlsread('fin.xlsx');
G = NAR';
Entrada16 = mapminmax('apply', G, ps);
simulacion16 = sim(net, Entrada16);
[Pronostico16] = mapminmax('reverse', simulacion16, ts);
%ESTADISTICAS
error=TN-output;
e2=error.^2;
Se2=sum(e2);
```

```

Mmse=Se2/length(TN);
Mmape=(sum(abs((error./TN)))/length(TN))*100;
xlswrite('W1c.xlsx', W1c);
xlswrite('W2c.xlsx', W2c);
xlswrite('W3c.xlsx', W3c);
xlswrite('B1c.xlsx', B1c);
xlswrite('B2c.xlsx', B2c);
xlswrite('B3c.xlsx', B3c);

```

### 3.b. Código redes neuronales de variables independientes

```

%MODELAMIENTO DE LA TEMPERATURA SUPERFICIAL DEL MAR EN ZONA NIÑO EN ZONA
1+2
x=xlsread('data 3.xlsx');x=x(:,2);m=12;N=[];pron=[];
k=1;n=length(x);meses=7;[PS, ps]= mapminmax (x');y=PS';
for i=1:n-m
    for j=1:m+1
        N(i,j)=y(k);k=k+1;
    end
    k=k-m;
end
N=N';
PN = N(1:m, : );
TN = N(m+1, :);
% DEFINICIÓN DE PARÁMETROS Y CREACIÓN DE RED
net = newff(PN, TN, [25], {'tansig', 'tansig'}, 'trainlm');
net.trainParam.epochs = 1000;
net.trainParam.max_fail= 50;
net.trainParam.goal = 0.0000000001;
%DIVISIÓN DE DATOS
testset.P = PN(:, 380:n-m);
testset.T = TN(:, 380:n-m);
valset.P=PN(:,313:379);
valset.T=TN(:,313:379);
%ERROR CUADRÁTICO MEDIO
net.performFcn = 'mse';
%ENTRENAMIENTO DE LA RNA
[net, tr] = train(net, PN, TN, [], [], testset, valset);
output = sim(net, PN);
Targets = mapminmax('reverse', TN, ps);
[Salida] = mapminmax('reverse', output, ps);
%GRÁFICA
%plot (Targets, 'ob');
%hold on;
%plot(Salida, '+r');
%PESOS Y BIAS POR CADA CAPA
v1c = net.iw{1,1} ;           % iw: Capa de entrada
v2c = net.lw{2,1} ;           % lw: Segunda Capa
b1c = net.b{1} ;              %bias 1ra capa
b2c = net.b{2} ;              %bias 2da capa

%PRONÓSTICO
pRo=1;n1=length(x);
while pRo<=meses
simul=sim(net, (PN(:,n1-m)));PS=[PS simul];W=[];n1=length(PS);k=1;i=1;j=1;
for i=1:n1-m
    for j=1:m+1
        W(i,j)=PS(k);k=k+1;

```

```

        end
        k=k-m;
end
W=W';
Inputs2 = W(1:m, : );
Targets2=W(m+1,:);
PN=[PN Inputs2(:,n1-m)];
pRo=pRo+1;
end
pron=mapminmax('reverse',Targets2(n-m+1:n-m+meses),ps);
ecm=mse(Salida-x(m+1:n,:))
end
xlswrite('W1c.xlsx', W1c);
xlswrite('W2c.xlsx', W2c);
xlswrite('B1c.xlsx', B1c);
xlswrite('B2c.xlsx', B2c);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%MODELAMIENTO DE LA TEMPERATURA SUPERFICIAL DEL MAR EN ZONA NIÑO 3
x=xlsread('data 3.xlsx');x=x(:,3);m=12;N=[];pron=[];
k=1;n=length(x);meses=7;[PS, ps]= mapminmax (x');y=PS';
for i=1:n-m
    for j=1:m+1
        N(i,j)=y(k);k=k+1;
    end
    k=k-m;
end
N=N';
PN = N(1:m, : );
TN = N(m+1, : );
% DEFINICIÓN DE PARÁMETROS Y CREACIÓN DE RED
net = newff(PN, TN, [25], {'tansig', 'tansig'}, 'trainlm');
net.trainParam.epochs = 1000;
net.trainParam.max_fail= 50;
net.trainParam.goal = 0.0000000001;
%DIVISIÓN DE DATOS
testset.P = PN(:, 380:n-m);
testset.T = TN(:, 380:n-m);
valset.P=PN(:,313:379);
valset.T=TN(:,313:379);
%ERROR CUADRÁTICO MEDIO
net.performFcn = 'mse';
%ENTRENAMIENTO DE LA RNA
[net, tr] = train(net, PN, TN, [], [], testset, valset);
output = sim(net, PN);
Targets = mapminmax('reverse', TN, ps);
[Salida] = mapminmax('reverse', output, ps);
%GRÁFICA
plot (Targets, 'ob');
hold on;
plot(Salida, '+r');
%PESOS Y BIAS POR CADA CAPA
W1c = net.iw{1,1} ;           % iw: Capa de entrada
W2c = net.lw{2,1} ;           % lw: Segunda Capa
B1c = net.b{1} ;              %bias 1ra capa
B2c = net.b{2} ;              %bias 2da capa
%PRONÓSTICO
pRo=1;n1=length(x);

```



```

while pRo<=meses
simul=sim(net, (PN(:,n1-m)));PS=[PS simul];W=[];n1=length(PS);k=1;i=1;j=1;
for i=1:n1-m
    for j=1:m+1
        W(i,j)=PS(k);k=k+1;
    end
    k=k-m;
end
W=W';
Inputs2 = W(1:m, : );
Targets2=W(m+1,:);
PN=[PN Inputs2(:,n1-m)];
pRo=pRo+1;
end
pron=mapminmax('reverse',Targets2(n-m+1:n-m+meses),ps);
ecm=mse(Salida-x(m+1:n,:))
end

xlswrite('W1c.xlsx', W1c);
xlswrite('W2c.xlsx', W2c);
xlswrite('B1c.xlsx', B1c);
xlswrite('B2c.xlsx', B2c);

%%%%%%%%%%
%MODELAMIENTO DE LA TEMPERATURA SUPERFICIAL DEL MAR EN ZONA NIÑO 4
x=xlsread('data 3.xlsx');x=x(:,4);m=12;N=[];pron=[];
k=1;n=length(x);meses=7;[PS, ps]= mapminmax (x');y=PS';
for i=1:n-m
    for j=1:m+1
        N(i,j)=y(k);k=k+1;
    end
    k=k-m;
end
N=N';
PN = N(1:m, : );
TN = N(m+1, :);
% DEFINICIÓN DE PARÁMETROS Y CREACIÓN DE RED
net = newff(PN, TN, [25], {'tansig', 'tansig'}, 'trainlm');
net.trainParam.epochs = 1000;
net.trainParam.max_fail= 50;
net.trainParam.goal = 0.0000000001;
%DIVISIÓN DE DATOS
testset.P = PN(:, 380:n-m);
testset.T = TN(:, 380:n-m);
valset.P=PN(:,313:379);
valset.T=TN(:,313:379);
%ERROR CUADRÁTICO MEDIO
net.performFcn = 'mse';
%ENTRENAMIENTO DE LA RNA
[net, tr] = train(net, PN, TN, [], [], testset, valset);
output = sim(net, PN);
Targets = mapminmax('reverse', TN, ps);
[Salida] = mapminmax('reverse', output, ps);
%GRÁFICA
%plot (Targets, 'ob');
%hold on;
%plot(Salida, '+r');
%PESOS Y BIAS POR CADA CAPA

```

```

W1c = net.iw{1,1} ;           % iw: Capa de entrada
W2c = net.lw{2,1} ;           % lw: Segunda Capa
B1c = net.b{1} ;              %bias 1ra capa
B2c = net.b{2} ;              %bias 2da capa
%PRONÓSTICO
pRo=1;n1=length(x);
while pRo<=meses
simul=sim(net, (PN(:,n1-m)));PS=[PS simul];W=[];n1=length(PS);k=1;i=1;j=1;
for i=1:n1-m
    for j=1:m+1
        W(i,j)=PS(k);k=k+1;
    end
    k=k-m;
end
W=W';
Inputs2 = W(1:m, : );
Targets2=W(m+1,:);
PN=[PN Inputs2(:,n1-m)];
pRo=pRo+1;
end
pron=mapminmax('reverse',Targets2(n-m+1:n-m+meses),ps);
ecm=mse(Salida-x(m+1:n,:))
xlswrite('W1c.xlsx', W1c);
xlswrite('W2c.xlsx', W2c);
xlswrite('B1c.xlsx', B1c);
xlswrite('B2c.xlsx', B2c);

%%%%%%%%%%
%MODELAMIENTO DE LA TEMPERATURA SUPERFICIAL DEL MAR EN ZONA NIÑO 3.4
x=xlsread('data 3.xlsx');x=x(:,5);m=12;N=[];pron=[];
k=1;n=length(x);meses=7;[PS, ps]= mapminmax (x');y=PS';
for i=1:n-m
    for j=1:m+1
        N(i,j)=y(k);k=k+1;
    end
    k=k-m;
end
N=N';
PN = N(1:m, : );
TN = N(m+1, : );
% DEFINICIÓN DE PARÁMETROS Y CREACIÓN DE RED
net = newff(PN, TN, [25], {'tansig', 'tansig'}, 'trainlm');
net.trainParam.epochs = 1000;
net.trainParam.max_fail= 50;
net.trainParam.goal = 0.0000000001;
%DIVISIÓN DE DATOS
testset.P = PN(:, 380:n-m);
testset.T = TN(:, 380:n-m);
valset.P=PN(:,313:379);
valset.T=TN(:,313:379);
%ERROR CUADRÁTICO MEDIO
net.performFcn = 'mse';
%ENTRENAMIENTO DE LA RNA
[net, tr] = train(net, PN, TN, [], [], testset, valset);
output = sim(net, PN);
Targets = mapminmax('reverse', TN, ps);
[Salida] = mapminmax('reverse', output, ps);
%GRÁFICA
plot (Targets, 'ob');

```

```

%hold on;
%plot(Salida, '+r');
%PESOS Y BIAS POR CADA CAPA
W1c = net.iw{1,1} ; % iw: Capa de entrada
W2c = net.lw{2,1} ; % lw: Segunda Capa
B1c = net.b{1} ; %bias 1ra capa
B2c = net.b{2} ; %bias 2da capa
%PRONÓSTICO
pRo=1;n1=length(x);
while pRo<=meses
simul=sim(net, (PN(:,n1-m)));PS=[PS simul];W=[];n1=length(PS);k=1;i=1;j=1;
for i=1:n1-m
for j=1:m+1
W(i,j)=PS(k);k=k+1;
end
k=k-m;
end
W=W';
Inputs2 = W(1:m, :);
Targets2=W(m+1,:);
PN=[PN Inputs2(:,n1-m)];
pRo=pRo+1;
end
pron=mapminmax('reverse',Targets2(n-m+1:n-m+meses),ps);
ecm=mse(Salida-x(m+1:n,:))
xlswrite('W1c.xlsx', W1c);
xlswrite('W2c.xlsx', W2c);
xlswrite('B1c.xlsx', B1c);
xlswrite('B2c.xlsx', B2c);

```

%%%

```

%MODELAMIENTO DE LA VELOCIDAD DE VIENTOS ALISIOS
x=xlswread('data 3.xlsx');x=x(:,6);m=12;N=[];pron=[];
k=1;n=length(x);meses=7;[PS, ps]= mapminmax (x');y=PS';
for i=1:n-m
for j=1:m+1
N(i,j)=y(k);k=k+1;
end
k=k-m;
end
N=N';
PN = N(1:m, :);
TN = N(m+1, :);
% DEFINICIÓN DE PARÁMETROS Y CREACIÓN DE RED
net = newff(PN, TN, [24], {'tansig', 'tansig'}, 'trainlm');
net.trainParam.epochs = 1000;
net.trainParam.max_fail= 50;
net.trainParam.goal = 0.0000000001;
%DIVISIÓN DE DATOS
testset.P = PN(:, 380:n-m);
testset.T = TN(:, 380:n-m);
valset.P=PN(:,313:380);
valset.T=TN(:,313:380);
%ERROR CUADRÁTICO MEDIO
net.performFcn = 'mse';
%ENTRENAMIENTO DE LA RNA
[net, tr] = train(net, PN, TN, [], [], testset, valset);

```

```

output = sim(net, PN);
Targets = mapminmax('reverse', TN, ps);
[Salida] = mapminmax('reverse', output, ps);
%GRÁFICA
%plot (Targets, 'ob');
%hold on;
%plot(Salida, '+r');
%PESOS Y BIAS POR CADA CAPA
W1c = net.iw{1,1} ;           % iw: Capa de entrada
W2c = net.lw{2,1} ;           % lw: Segunda Capa
B1c = net.b{1} ;              %bias 1ra capa
B2c = net.b{2} ;              %bias 2da capa
%PRONÓSTICO
pRo=1;n1=length(x);
while pRo<=meses
simul=sim(net, (PN(:,n1-m)));PS=[PS simul];W=[];n1=length(PS);k=1;i=1;j=1;
for i=1:n1-m
    for j=1:m+1
        W(i,j)=PS(k);k=k+1;
    end
    k=k-m;
end
W=W';
Inputs2 = W(1:m, : );
Targets2=W(m+1,:);
PN=[PN Inputs2(:,n1-m)];
pRo=pRo+1;
end
pron=mapminmax('reverse',Targets2(n-m+1:n-m+meses),ps);
ecm=mse(Salida-x(m+1:n,:))

end

xlswrite('W1c.xlsx', W1c);
xlswrite('W2c.xlsx', W2c);
xlswrite('B1c.xlsx', B1c);
xlswrite('B2c.xlsx', B2c);

```

## ANEXO 4

### BASE DE DATOS

Base de datos

AÑO	MES	PRECIPITACION (mm)	NIÑO 1+2 (°C)	NIÑO 3 (°C)	NIÑO 4 (°C)	NIÑO 3.4 (°C)	VELOC. VIENTOS (m/s)
1979	ENE	1.7	24.97	25.39	28.38	26.48	15.5
	FEB	0	25.74	26.17	28.21	26.59	14.9
	MAR	1	26.07	27.27	28.27	27.41	24
	ABR	3	25.63	27.76	28.51	27.93	7.5
	MAY	8.7	24.52	27.34	28.76	27.88	7.4
	JUN	0	23.29	26.63	28.74	27.59	3.8
	JUL	0	21.92	25.66	28.67	27.05	-3.8
	AGO	0	21.08	25.3	28.49	26.85	-7
	SEP	0.3	21.01	25.6	28.66	27.14	-2.6
	OCT	0.3	21.4	25.5	28.73	26.92	5.9
	NOV	0	21.77	25.64	28.91	27.1	4.9
	DIC	0	22.81	25.73	28.75	27.18	10.5
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1983	ENE	324.5	27.2	28.47	28.75	28.82	0.8
	FEB	161.7	28.16	28.63	28.61	28.68	0.3
	MAR	427.1	29	28.85	28.58	28.72	-6.1
	ABR	778.4	28.94	29.09	28.72	28.83	-6.8
	MAY	379.4	28.27	28.95	29.09	28.89	-1.5
	JUN	192.4	27.24	28.13	28.95	28.33	0.2
	JUL	0.7	25.84	26.76	28.69	27.25	-2.4
	AGO	0.5	24.01	26	28.46	26.76	0.2
	SEP	0	22.37	25.3	28.22	26.42	-0.9
	OCT	0	22.24	24.73	28.05	25.89	5.8
	NOV	0.1	22.38	24.42	27.94	25.74	12
	DIC	8.5	23.26	24.73	27.88	25.87	13.6
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1998	ENE	769.2	28.01	28.67	28.98	28.93	-2.7
	FEB	501.8	28.83	28.82	28.86	28.77	-2.8
	MAR	479.9	29.12	29.15	28.65	28.68	-5.7
	ABR	90.9	28.23	29.24	28.59	28.72	-6.4
	MAY	5.6	27.18	28.68	28.9	28.63	1
	JUN	0	25.33	27.11	28.63	27.57	3.3

	JUL	0	23.41	25.71	28.42	26.55	2.1
	AGO	0	22.11	24.76	28.1	25.82	-5.7
	SEP	0.2	21.25	24.24	28.1	25.72	-3.7
	OCT	2	21.56	24.36	27.7	25.55	3.5
	NOV	0.1	21.64	24.59	27.51	25.57	12.9
	DIC	0.2	23.01	24.45	27.24	25.2	15.8
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015	ENE	0.2	24.68	26.25	29.1	27.21	11.8
	FEB	0.3	25.84	26.67	28.99	27.23	18.2
	MAR	44.3	26.69	27.51	29.16	27.77	15.3
	ABR	1.6	26.29	28.23	29.61	28.58	2.9
	MAY	1.8	25.68	28.19	29.83	28.82	-2.5
	JUN	0	25.13	27.87	29.77	28.7	0.1
	JUL	0	24.3	27.4	29.58	28.5	-5
	AGO	0	22.83	27.06	29.57	28.47	-4.9
	SEP	0	22.96	27.12	29.63	28.62	-7.3
	OCT	0	23.08	27.37	29.73	28.87	-6.7
	NOV	0	23.87	27.72	29.99	29.14	-0.4
	DIC	0	24.86	27.83	29.87	29.04	6.1

\*El cuadro anterior muestra la base de datos utilizada en el estudio, los datos de las precipitaciones fueron proporcionados por el Proyecto Especial Chira Piura, los datos de las temperaturas superficiales del mar de las diferentes zonas al igual que la velocidad de los vientos alisios fueron extraídos de la página de NOAA.

La información completa se encuentra archivada en el CD adjunto.

**ANEXO 5**

**PRONÓSTICO DE PRECIPITACIONES CON METODO DE WINTERS**

Pronóstico con método de Winters

<b>AÑO</b>	<b>MES</b>	<b>Precipitaciones Reales (mm)</b>	<b>Pronóstico precipitaciones - Winter (mm)</b>
1979	ENE	1,7	5.17
	FEB	0	1.31
	MAR	1	0
	ABR	3	0.16
	MAY	8,7	0.79
	JUN	0	3.74
	JUL	0	0
	AGO	0	0
	SEP	0,3	0
	OCT	0,3	4.21
	NOV	0	0.61
	DIC	0	0
⋮	⋮	⋮	⋮
1983	ENE	324,5	44.94
	FEB	161,7	342.91
	MAR	427,1	251.96
	ABR	778,4	300.59
	MAY	379,4	249.89
	JUN	192,4	166.51
	JUL	0,7	8.54
	AGO	0,5	0.11
	SEP	0	0.61
	OCT	0	0
	NOV	0,1	0
	DIC	8,5	0.45
⋮	⋮	⋮	⋮
1998	ENE	769,2	742.19
	FEB	501,8	814.19
	MAR	479,9	783.11
	ABR	90,9	338.17
	MAY	5,6	29.13

	JUN	0	2.39
	JUL	0	0
	AGO	0	0
	SEP	0,2	0
	OCT	2	2.8
	NOV	0,1	4.1
	DIC	0,2	0.47
⋮	⋮	⋮	⋮
2015	ENE	0,2	0
	FEB	0,3	0
	MAR	44,3	0
	ABR	1,6	30.68
	MAY	1,8	0.35
	JUN	0	0.71
	JUL	0	0
	AGO	0	0
	SEP	0	0
	OCT	0	0
	NOV	0	0
	DIC	0	0

**\*La información completa se encuentra archivada en el CD adjunto.**



**ANEXO 6**

**PRONÓSTICO DE TEMPERATURA SUPERFICIAL DEL MAR Y VELOCIDAD DE VIENTOS ALISIOS CON RED NEURONAL**

<b>AÑO</b>	<b>MES</b>	<b>Pronóstico Niño 1+2 (°C)</b>	<b>Pronóstico Niño 3 (°C)</b>	<b>Pronóstico Niño 4 (°C)</b>	<b>Pronóstico Niño 3.4 (°C)</b>	<b>Pronóstico Velocidad Vientos (m/s)</b>
<b>1980</b>	ENE	24.6218	26.2036	28.6293	27.1373	13.7213
	FEB	25.8685	26.5461	28.5048	27.0812	7.8492
	MAR	26.5281	27.1284	28.4777	27.3921	12.8608
	ABR	25.7334	27.5596	28.7707	27.8624	7.1139
	MAY	24.3495	27.3286	29.1856	28.1566	3.9715
	JUN	22.9901	26.8059	29.0935	28.0466	-0.3262
	JUL	21.2400	25.7231	28.9940	27.4687	-0.1380
	AGO	20.5936	24.9775	28.5552	26.7518	-1.4296
	SEP	20.3899	24.9083	28.5970	26.5930	-4.2154
	OCT	20.7518	24.7474	28.7599	26.5822	4.1810
	NOV	21.4838	25.0856	28.6953	26.6950	8.8114
	DIC	22.4854	25.3646	28.5073	26.8379	12.0548
⋮	⋮	⋮	⋮	⋮	⋮	⋮
<b>1983</b>	ENE	27.1857	28.4707	28.7572	28.8327	1.4213
	FEB	28.2042	28.6082	28.6092	28.6814	1.0233
	MAR	28.8850	28.8729	28.5811	28.7055	-6.6190
	ABR	28.8855	29.0869	28.7194	28.9048	-6.3851
	MAY	28.2819	28.9441	29.0974	28.8535	-0.9809
	JUN	27.2397	28.1261	28.9490	28.3369	-0.2285
	JUL	25.8377	26.7462	28.6824	27.2555	-0.7199
	AGO	24.0133	25.9827	28.4353	26.7675	-0.1830
	SEP	22.3547	25.3018	28.2161	26.4111	-0.9463
	OCT	22.2333	24.7391	28.0697	25.8882	5.4645
	NOV	22.3854	24.4227	27.9416	25.7209	11.4469
	DIC	23.2549	24.7254	27.8869	25.8747	13.5278
⋮	⋮	⋮	⋮	⋮	⋮	⋮
<b>1998</b>	ENE	28.0086	28.7004	29.0317	28.8923	-2.5176
	FEB	28.8578	28.8452	28.8509	28.7719	-3.3819
	MAR	29.0382	29.1339	28.6503	28.6904	-7.9194
	ABR	28.2331	29.1706	28.5898	28.7027	-7.4140
	MAY	27.1710	28.7140	28.8969	28.6361	1.0654
	JUN	25.3362	27.1070	28.6274	27.5738	3.3950
	JUL	23.4200	25.7154	28.4241	26.5573	1.4473
	AGO	22.1159	24.7796	28.0910	25.8266	-4.1764

	SEP	21.2581	24.2157	28.0983	25.7140	-3.5109
	OCT	21.5566	24.3734	27.6891	25.5481	4.0187
	NOV	21.6495	24.5898	27.5085	25.5727	12.4542
	DIC	23.0087	24.4438	27.2518	25.2039	15.8433
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015	ENE	24.6654	26.2572	29.0901	27.1644	11.1263
	FEB	25.7915	26.6538	28.9850	27.2203	18.9289
	MAR	26.6805	27.4866	29.1482	27.7627	15.0535
	ABR	26.3154	28.2409	29.5394	28.5688	3.6315
	MAY	25.6993	28.2285	29.8586	28.7537	-3.0646
	JUN	25.1429	27.9094	29.7503	28.6276	-0.4568
	JUL	24.2669	27.3732	29.5537	28.4637	-4.0820
	AGO	22.9234	27.0612	29.5555	28.4222	-4.7429
	SEP	22.9572	27.0579	29.6167	28.5928	-7.7557
	OCT	23.0822	27.3624	29.7032	28.8708	-7.0283
	NOV	23.8711	27.7062	29.8278	29.1247	-0.0632
	DIC	24.8742	27.8253	29.8080	29.0091	6.2888

**\*La información completa se encuentra archivada en el CD adjunto.**

**ANEXO 7**

**PRONÓSTICO DE PRECIPITACIONES CON RED NEURONAL**

<b>AÑO</b>	<b>MES</b>	<b>Precipitaciones Reales (mm)</b>	<b>Pronóstico de Precipitaciones (mm)</b>
<b>1979</b>	<b>ENE</b>	<b>1.7</b>	<b>1.8346</b>
	<b>FEB</b>	<b>0.0</b>	<b>-0.0233</b>
	<b>MAR</b>	<b>1.0</b>	<b>1.0074</b>
	<b>ABR</b>	<b>3.0</b>	<b>2.9962</b>
	<b>MAY</b>	<b>8.7</b>	<b>2.1419</b>
	<b>JUN</b>	<b>0.0</b>	<b>0.7481</b>
	<b>JUL</b>	<b>0.0</b>	<b>0.2214</b>
	<b>AGO</b>	<b>0.0</b>	<b>0.0794</b>
	<b>SEP</b>	<b>0.3</b>	<b>0.1993</b>
	<b>OCT</b>	<b>0.3</b>	<b>0.3320</b>
	<b>NOV</b>	<b>0.0</b>	<b>0.3602</b>
	<b>DIC</b>	<b>0.0</b>	<b>1.2811</b>
⋮	⋮	⋮	⋮
<b>1983</b>	<b>ENE</b>	<b>324.5</b>	<b>324.5025</b>
	<b>FEB</b>	<b>161.7</b>	<b>161.6954</b>
	<b>MAR</b>	<b>427.1</b>	<b>427.0893</b>
	<b>ABR</b>	<b>778.4</b>	<b>778.3925</b>
	<b>MAY</b>	<b>379.4</b>	<b>379.3946</b>
	<b>JUN</b>	<b>192.4</b>	<b>192.4047</b>
	<b>JUL</b>	<b>0.7</b>	<b>0.6407</b>
	<b>AGO</b>	<b>0.5</b>	<b>0.8377</b>
	<b>SEP</b>	<b>0.0</b>	<b>0.7416</b>
	<b>OCT</b>	<b>0.0</b>	<b>0.2647</b>
	<b>NOV</b>	<b>0.1</b>	<b>-0.0767</b>
	<b>DIC</b>	<b>8.5</b>	<b>8.5305</b>
⋮	⋮	⋮	⋮
<b>1998</b>	<b>ENE</b>	<b>769.2</b>	<b>769.2005</b>
	<b>FEB</b>	<b>501.8</b>	<b>501.7962</b>
	<b>MAR</b>	<b>479.9</b>	<b>479.9005</b>
	<b>ABR</b>	<b>90.9</b>	<b>90.9065</b>
	<b>MAY</b>	<b>5.6</b>	<b>5.5447</b>
	<b>JUN</b>	<b>0.0</b>	<b>-0.2748</b>
	<b>JUL</b>	<b>0.0</b>	<b>1.0093</b>
	<b>AGO</b>	<b>0.0</b>	<b>0.2108</b>
	<b>SEP</b>	<b>0.2</b>	<b>0.0417</b>
	<b>OCT</b>	<b>2.0</b>	<b>1.8861</b>

	NOV	0.1	0.1178
	DIC	0.2	0.2228
⋮	⋮	⋮	⋮
2015	ENE	0.2	3.2896
	FEB	0.3	0.1825
	MAR	44.3	44.3210
	ABR	1.6	1.6009
	MAY	1.8	1.8034
	JUN	0.0	0.1344
	JUL	0.0	0.5250
	AGO	0.0	0.5487
	SEP	0.0	0.5226
	OCT	0.0	0.4606
	NOV	0.0	-0.2567
	DIC	0.0	0.3617

**\*La información completa se encuentra archivada en el CD adjunto.**

## ANEXO 8

### PESOS Y BIAS DE REDES NEURONALES ARTIFICIALES

#### 8.a. Precipitaciones

##### Pesos 1ra Capa (10x5)

-4.87800802	4.80269042	2.44795371	-2.09879688	-0.23778683
-3.20447666	-7.47834417	0.13289398	0.42654704	1.28872093
-6.80508955	1.66088284	2.84898358	-1.49443661	2.38052382
4.80586474	-4.94706423	3.0587683	-0.18644419	1.90334013
-0.98046342	0.24165994	1.84340475	0.06765411	-0.67173583
-5.8727311	-2.04153336	2.34112174	-1.78095676	1.14777036
-1.96029033	1.89076332	-1.46126042	3.51502324	-1.82596243
-0.13098532	1.56104747	-1.04951934	1.71886829	1.10307618
0.05311982	2.17173722	-0.54006623	1.30715841	-1.55728458
0.8671473	-2.16317916	3.67818204	0.71195461	-0.60718163

**Pesos 2da Capa (14x10)**

-0.46743178	-1.09952216	1.09836186	0.25633575	-0.77047147	-2.73003477	-2.73272722	0.29588458	0.7510968	0.7285728
-2.16565827	-2.2718252	-0.08568124	0.07701549	-1.03044213	0.05706853	-0.72022664	-0.06423279	-0.1708484	-0.28182076
0.95346188	1.22568862	1.02754782	-1.03153605	0.25681816	-2.04239297	1.24099521	0.28650772	-0.96710251	0.09269046
-1.48190844	-1.90430962	1.86076601	-1.27001755	-2.09580641	-2.22715994	-2.24931412	-0.33689267	0.53796669	0.3154021
0.82848023	2.83941699	0.56231218	-2.11790915	-1.3441156	0.66958275	1.81159015	-1.11311933	1.51834413	-0.39650764
0.02098817	-0.04205764	-0.15684929	-0.00813241	-0.00280454	0.06834496	-0.11151336	-0.00550596	0.22162149	-0.02169609
-1.53064564	-2.82440112	2.11169925	-1.03469816	-0.70733217	0.99787128	-0.92593536	-1.14592836	0.06712326	-1.70159668
3.13917057	-3.330904	2.6136547	-1.19365537	2.159205	1.00970859	0.81987858	0.20338542	-0.16019381	1.43435608
1.39167452	0.44756755	-0.951622	-2.05261242	-1.52968871	4.37745477	2.69394882	-1.22382978	1.54739411	-0.55728614
1.2758302	-2.05111917	-1.08783869	3.58578746	-0.21050512	-1.51047495	-0.90072457	0.59828409	-1.03678265	0.99874257
1.19681852	0.3994171	1.89151421	-0.12401916	2.35183758	-1.05048757	0.52984858	0.66107648	-0.68535815	-0.41316225
1.26595725	0.30896092	-0.69970117	-1.74115431	-1.1109241	3.50724116	0.77112277	0.38725319	1.23977795	-0.38414815
-1.78094803	-2.9230969	-0.36410634	1.30567517	0.5525927	-0.18410303	1.4207668	0.59046914	-0.89506445	0.26950717
-2.12359835	-3.7404974	0.19541127	-2.10033599	3.80155998	0.5051559	-0.92559885	-1.35894268	-2.28217217	-1.70032311

**Pesos 3ra capa (1x14)**

-0.96310162	-0.4473548	-0.14345383	0.27990089	2.39322547	-0.29722453	-0.18960377	...
...	-0.07669276	-0.79723751	1.44790969	-0.27684896	0.96214722	1.70207593	2.53077988

**Bias 1ra Capa (10x1)**

-0.05655823
3.83784736
2.29440539
-1.00434544
0.3736382
1.94527683
2.1236668
0.77392741
3.51117183
2.32931373

**Bias 2da Capa (14x1)**

-2.48263155
0.92388651
2.67088758
-1.66694263
0.51913997
-0.6978879
-1.52381391
0.62199241
0.88123975
-1.12716014
0.84680293
1.13923903
-2.90870583
-2.65206484

**Bias 3ra Capa (1x1)**

1.1180556
-----------

8.b. TSM NIÑO 1+2

Pesos 1ra Capa (25x12)

1.6215544	18.2039308	-9.45899419	10.6819701	9.11713841	1.17863667	12.4957811	-7.52420478	-31.851725	48.5887585	-17.2057263	-10.6719822
2.3870579	3.0733266	-40.2608449	-0.47412426	-22.3102205	42.6780217	-70.357112	54.2629205	27.2487448	34.0544418	37.3003233	-34.8934777
.21373282	-0.04215862	0.45149405	7.77261679	-1.35218872	2.05160086	8.64628186	9.54922155	18.4417643	11.8898776	-1.45141911	-14.4973333
1.0310726	30.0234034	3.57509617	26.4450738	18.7630636	-120.079976	42.5770296	-145.401739	-18.6997624	84.3825457	-48.1973601	6.39569075
.14531123	3.22287759	-0.54680966	-1.07842	15.6915657	-12.3382433	-7.03790664	16.3593676	0.80597385	2.59415374	-9.08529234	0.83836214
4.6173313	-73.1554475	-12.6476098	-30.5552802	73.8311278	-39.325308	56.883504	70.5074233	-107.407769	113.284328	-56.968192	-6.09788829
.16650011	2.79872388	4.17783941	-12.7134846	8.01550829	-9.02212073	7.19643843	5.45342367	-10.1330931	6.87826255	-2.76224319	3.62555655
.09864342	-10.4086608	0.82417237	0.29124349	-3.38761383	0.86440413	4.52207371	-7.94202331	14.2976952	-7.72566294	4.70639503	1.23619671
1.6888052	-24.650809	34.1179405	-29.256058	-33.3469582	26.5541955	-29.8326002	-13.1885337	8.85323812	-39.3360227	16.5269544	16.5926296
.12443389	9.65365986	3.78480373	-7.92325847	2.23979706	-3.66619165	-0.23993761	-1.53684799	-1.54691992	3.13829628	-2.34171515	-5.16274911
6.3069781	-96.0259247	-96.7882743	117.030451	-99.4227002	28.0121304	-108.275003	84.3627045	-10.6994435	-32.9425841	41.3580755	31.6923532
6.2587958	-70.7473702	77.4130913	-114.379369	43.0649317	4.41416382	-32.1128532	-4.37749339	40.3005393	-95.9434798	70.5146021	15.8230692
.91366251	1.69181207	-4.11558691	-8.38562181	-0.16631366	1.01895637	-13.8704978	-10.148592	-27.4940865	-11.2300877	5.56761083	11.2899779
8.5028052	-26.2059657	-12.5372139	14.0551272	-38.3559312	22.6895994	13.3023292	-26.2736059	-5.44786732	20.1111439	-0.40936779	-6.77114137
0.4472623	-15.0445566	0.17127798	3.69403425	-2.35856721	7.15288243	2.92612479	0.85491107	4.13544172	-5.30568253	0.66887201	7.17757118
4.3046433	37.563646	52.3322696	15.3833177	-8.88631973	30.8742698	12.423152	23.6608108	-33.1070967	118.895455	-51.6660549	46.5741303
.10838205	3.15939413	-2.10906226	0.32227632	7.520496	-2.32588699	8.77013454	-3.29737584	5.60186746	-9.85699441	7.80382874	-5.0800471
7.3281187	-1.58538525	-12.9446264	25.0969644	-0.15796084	19.1435107	12.1467685	-19.1040944	9.47196254	17.7752386	-13.836349	9.00791981
.89930064	0.91388346	-6.07204021	3.54501154	-0.3506377	1.36347154	5.18347283	-7.02065545	0.51758962	-1.83209425	1.2177156	4.24566277
.32839579	-2.28197564	14.3163847	-3.00522301	22.5749231	-25.9588591	-20.7662448	27.2953282	4.69638566	26.3897182	-14.4858728	-32.8588342
.19702773	-0.05780422	11.9090211	-15.6073216	14.0259606	-1.37626235	-4.17037824	10.1305372	-4.46327356	3.21820175	-2.16060565	-0.54721603
.10869065	4.08629196	17.0954145	-24.4522094	15.4863668	5.68775357	-0.51562982	12.17096	-13.6067285	6.04252076	2.22488609	0.07714323
4.5590637	-1.19464912	-3.72968107	-1.02975766	6.14914738	-7.76206237	4.24311149	2.69479599	7.24623504	-5.2462013	-3.52768637	9.54436158
.62321076	14.3840754	-13.4896251	25.0513521	-24.5924377	30.5149915	1.80933419	-37.2294273	22.3827431	9.36575593	-7.1258958	9.88202873
.50850322	6.03885138	-7.3805489	5.46999431	11.2123365	-2.36501295	16.8466944	-6.81994486	10.8474123	-14.752257	7.66809343	-1.15335858



**Pesos 2da Capa (1x25)**

-0.19361702	-0.14646479	-3.32425453	0.10102756	2.9431531	-0.17182269	...
...	0.31582811	-0.37730389	0.24224718	-0.36325938	-0.11634582	...
...	0.18048436	-3.28429914	0.18726585	-0.35848889	0.10880325	...
...	-0.58563712	0.20775805	-0.62771908	-0.32330113	-2.98481813	...
...	0.67502332	0.35603137	0.30839728	0.47198015		

**Bias 1ra Capa (25x1)**

-4.89526429
1.34785526
-2.64632358
-111.479007
-4.73135632
17.6542985
-3.58196612
7.07078801
-2.97434124
0.09203001
8.57150381
28.9185156
1.82042765
8.85236103
-0.34412385
81.741648
5.24840027
11.2579771
2.8005733
-15.4546386
-3.54981888
-3.03716752
5.85921121
-5.57705058
10.8608237

**Bias 2da Capa (1x1)**

0.81358799
------------

8.c. TSM NIÑO 3

Pesos 1ra Capa (25x12)

1.75572276	1.88683497	-5.32095365	9.93320742	-12.3905229	8.22325127	-1.72109311	1.31869449	0.18840979	3.12556304	2.58068301	0.92772846
1.85696961	-6.56131007	-11.4207827	10.1710403	-5.83318035	-3.28326295	-13.3386515	9.01047023	-10.727134	9.50313098	-10.8282514	5.47718927
3.14341435	-3.20261982	1.71896415	-1.25457937	0.41736868	2.81086836	1.28136061	-0.45650719	0.81546688	0.03368845	-5.74562852	5.44782784
4.60974126	-4.70586285	6.39854778	4.58627494	-5.52394182	-0.15096073	2.45815891	-2.61138977	-2.3315272	0.57060334	-7.46353074	5.32026773
0.21303071	-5.62391062	10.3646313	7.13541195	-10.1101464	0.14978511	-5.12091443	3.83484298	-7.76481337	-0.76646008	5.63552669	-2.53651668
0.20318491	-0.8062815	2.94031034	-2.3944438	0.31868584	-1.39443953	0.79838759	0.09579669	-0.72623856	-2.90558769	3.14879982	-0.34675911
0.16907864	-0.9817534	2.72803185	-2.27976529	0.56472586	-1.28099343	0.33824451	0.49945108	-1.34028032	-2.07079137	2.50558777	-0.18238497
3.66039	-8.04738847	8.34002115	-6.86066091	0.47905532	-1.55434419	8.65246449	-6.38825788	-2.64331825	3.07543427	0.93411899	-9.97274818
-0.27159486	-0.43254765	1.72515576	-0.66479146	-0.07866365	-0.96874122	-0.92253612	2.02104658	-4.1178265	1.55783592	-0.07752275	-0.00940531
3.83252139	-3.67177496	5.32513509	5.22911506	-6.196292	1.14005072	1.46392281	-2.4118927	-1.70368165	0.03380287	-6.96661983	5.32227614
1.31215084	-2.50715842	5.71468071	-1.97055448	-0.92495118	4.5181548	-2.61736113	1.14920239	-0.97795769	1.1137432	3.80570805	-1.80882735
5.7741425	-7.23268144	-6.5282659	15.0335085	-4.27131771	5.19483296	1.39528876	-1.17383727	6.19603318	-1.06917416	-1.91283355	6.23466409
-3.64254399	3.22940108	0.57800266	-3.48881784	1.44663642	0.34462573	2.62046449	0.72318086	-1.33520686	-3.48967633	0.429957	0.51931923
-0.94359037	2.47866657	0.03464199	-3.75498783	4.11454207	-3.95890936	4.181118	-1.39953066	-1.91582807	1.14265148	-4.49746323	1.03036848
-2.8067299	4.14421834	-0.83764055	6.94932791	-0.74535782	-4.58297142	21.0789831	-17.3222732	1.80549941	7.82099134	0.51972633	2.67803189
0.25924867	-1.0096712	-2.39704252	5.6319686	-6.82700128	6.50211119	-6.48846556	5.30797411	0.31192805	1.20698938	-3.34427463	1.59334809
0.98827683	0.00925646	-3.80363919	0.08660088	2.04760545	0.68520931	1.16673121	-3.78024601	7.54942948	-2.64119729	0.72716323	0.39638422
0.01721896	-0.34014055	-1.08530069	0.61240086	1.30576577	-3.22505487	5.3052696	-2.24977468	-1.09208111	0.57770107	0.81122362	-3.72098126
-0.08512835	0.77253988	0.47787262	-0.37148604	-1.88574996	3.41511515	-5.16187709	2.07078805	1.24465221	-0.15825483	-1.81543664	4.09284521
-12.0405583	14.9306174	-10.0837972	-2.74231973	4.51335118	-3.31048404	6.61509554	1.53905468	-4.69833189	-6.09311722	3.86008676	0.00112971
1.24734061	0.71964822	-2.06101016	1.71518515	-3.92712034	8.56386931	-5.83281796	6.46840149	2.11684052	-6.28080377	-5.31350958	9.58523458
0.22256307	0.51868913	-1.93716063	0.95448449	0.13100877	-0.10784974	0.47575223	-0.33304418	0.48185011	-0.972102	0.47160505	-0.71660955
-1.43262365	5.25108343	-5.62304678	7.67339747	-8.64346763	2.26343594	-1.43944493	3.21980313	-1.90976329	-8.03848304	5.9683679	1.19583997
1.19262133	-2.4950087	5.84016755	-1.9798121	-0.79909512	3.82752897	-2.25862604	0.96740019	-0.9222354	1.41470656	3.51129969	-1.71834809
0.16095499	-0.41783478	1.96388406	-0.65841755	-1.28785718	3.43432446	-5.66073293	2.66150021	0.7751159	-0.91491742	-0.1475066	3.99121792

**Pesos 2da Capa (1x25)**

0.29768565	0.23015246	-1.03948808	4.08722324	0.35745613	-8.00489716	...
...	9.31176007	-10.669326	-3.75363114	-4.22336819	7.61438646	...
...	0.25440454	-0.67055791	0.61093261	-0.16611537	-0.44295177	...
...	-1.35038465	14.122821	6.79582175	0.37923633	0.78828776	...
...	-9.86762872	0.63647815	-7.90550388	7.32123646		

**Bias 1ra Capa (25x1)**

-1.04724868
-15.0627851
-2.54732718
-5.28235996
-4.02444513
-1.62420522
-1.65505305
-10.1390237
-1.69072597
-5.01803781
-2.12529904
-1.39936138
-1.31896239
-0.1120998
2.0366242
0.38872728
3.79201132
-2.57548148
2.48445268
-2.39197383
-3.74100095
1.82060773
-2.39281499
-2.09276249
2.83810597

**Bias 2da Capa (1x1)**

-1.38493159
-------------

8.d. TSM NIÑO 4

Pesos 1ra Capa (25x12)

-6.88273606	10.687147	0.2318	-3.79829258	0.45038504	11.6416519	-10.8818857	-7.47192998	11.2774145	-11.5894437	1.58901092	-6.50982859
-9.43587753	6.41113845	-1.96913725	3.85083451	-2.50243797	13.8223341	0.18440156	-8.70037849	1.71491135	-0.69592206	-7.28995191	7.62857018
-0.06650357	2.73242541	-1.92159739	-0.52708294	-0.55716756	0.88842158	-0.75605112	0.52320208	0.53454246	1.25839123	-0.26444595	2.04559905
-0.95317734	3.6984592	-1.1391417	0.31730321	-0.37321881	0.3875875	0.50422335	-0.81943876	1.51646718	-0.90850366	0.87518289	-0.41867359
-3.55524551	-10.0210983	17.0670928	-19.694866	21.4290734	5.46616152	8.26547053	16.4755389	-2.56685233	22.1860439	-11.4720059	-8.96439032
1.88685854	7.74517109	-14.7517971	-5.0564071	8.71701233	-1.80911054	-6.56487924	3.39973294	7.91272099	-3.13492729	15.0040268	-9.00632797
13.5078385	8.98329874	8.86076316	-15.4211636	-1.57331613	-26.0042893	-9.23851037	26.5302893	1.02216595	-7.61228877	6.88409005	-0.94253535
-2.91595157	6.26974323	0.60344078	-12.241114	1.21878406	1.54046147	1.35320834	-5.40274399	6.85645653	0.65601257	4.81014226	0.28755255
-2.4392158	-3.18902711	-8.84315118	5.56361235	-2.44704109	-2.56912502	-2.73903638	2.41493357	-0.12489674	-1.06143188	2.54545111	0.65887485
-0.02709386	3.01514975	0.87002674	36.7635062	-11.2758176	-15.0263777	8.97473397	36.4904222	-49.9811102	-53.146697	0.4042973	23.5424046
-5.33707734	7.51249627	-7.19455289	-2.91039663	2.70187611	2.03643225	-8.06283021	-0.05677006	-0.28293176	-1.982645	2.98367783	-2.75191433
3.23753401	-20.0314204	23.843247	-5.56154369	-8.03737294	-1.29839974	0.33342579	18.1069815	8.40777263	53.9483732	-26.7758578	-40.3750275
-0.96655481	0.89377354	-2.59147306	3.72505324	-0.8653647	-0.04012768	0.0935186	1.11653726	-1.89192706	-1.51617868	1.9292609	-2.99296556
-3.28755219	9.49467467	-5.36715374	-0.80198386	-6.38752886	-1.5035202	3.12567445	3.97628585	-4.71878742	8.34570941	-4.2823645	8.10540113
3.19205454	-12.9962276	4.9856979	3.17863149	1.35072102	-7.52994543	2.14499497	0.92695001	-7.05312378	17.2692492	-21.8189959	13.7954702
8.16522388	-28.4659935	-5.20323726	16.761461	19.2140921	4.78345437	-37.0963132	2.60399329	33.0227354	5.46725018	27.3604429	-31.882117
4.43451539	-6.41088835	6.18466608	2.28847306	-1.84906204	-1.82274089	6.57377296	-0.30929768	0.61987495	2.08147625	-3.26163883	2.70310343
-4.55279114	-9.74231431	16.8916154	-16.2597464	14.6600783	8.02702777	9.11732228	13.297455	-3.26592629	22.5660377	-10.35392	-7.6892884
-0.20418056	2.44927324	-0.19832796	-4.62768705	2.33788064	3.17884588	-2.5532195	-2.58541583	1.41196322	0.002293	1.33323429	-1.69560614
2.93759109	2.68662246	10.5821818	-6.66073878	3.25104992	2.44986948	3.0126484	-2.55292806	0.13118399	1.3910129	-3.14474661	-0.61083592
-10.9017644	43.214782	-16.8281669	0.6536733	8.02150909	-10.3505897	-15.0550793	32.9929234	8.49930424	-30.1981548	34.5237084	-35.7007447
10.4217891	-30.4164998	45.6444392	-23.0947085	-24.5278068	44.0569823	12.8297666	-19.6447771	28.1888051	2.31919158	-6.98033266	4.80968278
-1.57445552	5.7554346	-2.56792886	-3.55695697	1.8883147	1.97817056	-3.14225798	-0.49059889	0.22718052	-0.83206122	2.71731133	-2.68069044
7.10870562	-10.8745479	-0.08267802	3.62677343	-0.57802914	-11.5759467	11.1496728	7.17157861	-11.2434129	11.9467847	-1.86925174	6.78601991
-5.68265484	12.1568328	1.09477568	-2.71817387	-7.98531783	10.7516929	-18.3594348	6.98870672	-10.6385831	6.52935151	-14.0851414	4.6596912

**Pesos 2da Capa (1x25)**

6.03991286	0.22893457	1.01556204	-1.46764689	-1.37165159	-0.59580762	...
...	0.18135831	0.50890232	-9.52830965	0.14158305	4.84957757	...
...	-0.14583515	-0.59465635	-0.4013217	-0.15170251	0.20767989	...
...	5.40500511	1.51354046	-0.92578192	-9.13629503	-0.18869268	...
...	-0.25399237	0.9997227	5.95746935	-0.20890845		

**Bias 1ra Capa (25x1)**

1.89828449
-0.71659288
0.95616747
0.76634438
-0.33203644
3.8004216
0.72491143
2.16719481
-3.73335775
0.8855042
-1.65305487
3.80633886
2.1543275
2.86472158
-0.70640727
3.36548982
1.42584637
-0.82661364
-0.63345621
4.11260392
-16.5282546
-4.51876238
-1.04279776
-1.95175723
1.49151317

**Bias 2da Capa (1x1)**

0.65450465
------------

8.e. TSM NIÑO 3.4

Pesos 1ra Capa (25x12)

2.79883132	-2.63653972	-4.51050918	8.63978096	-4.13605362	-2.66287357	3.69218979	-4.77885332	3.14651505	-1.41695492	5.13170946	-7.33087002
-0.50421087	2.03981487	-1.48021322	-0.34668433	0.05846995	1.45677421	-2.56001872	2.61541167	1.92363635	-2.47384895	0.70282792	-1.67117928
-0.38892892	-0.66066765	0.58046397	-0.02498229	0.67776382	0.8518645	-0.13103683	-1.33534834	2.517267	-1.42154722	1.91597962	0.24411649
2.23993673	3.2876439	-7.9729386	4.05538698	-7.62901425	-0.59531844	1.93287581	-4.05551554	4.12523219	-3.24062826	2.28034622	-0.4706756
-1.90383922	3.95300082	-0.08929325	-2.47264425	4.77897684	-1.01875744	1.32167867	-2.31171297	0.38244386	0.58044077	0.02375006	-0.35753811
0.76620251	-4.1293435	0.5946148	3.3517271	-2.2788301	3.48206182	-3.11855993	2.74377932	3.14903854	-1.29943249	2.57965768	-2.2852361
-0.76572616	1.41259809	2.08363387	-3.48696412	-0.62374036	0.52593495	-1.09885838	0.17688337	-0.27547315	-0.30485647	-0.0173748	-0.97362848
1.16779866	0.55987127	-0.98277336	-1.72787512	-3.18246382	3.09798471	2.28326282	1.33188261	-3.05308588	2.26203204	0.09060076	-0.24740674
-3.04457583	5.55292261	0.14609095	-4.28575637	7.54716928	-10.019907	8.84132384	-2.10291074	1.71719151	-3.29688289	1.60438753	-0.30025103
2.7387827	-4.74261585	-0.74504333	3.59017571	-6.17654473	1.21686318	-2.47419387	3.7673063	-0.27054136	-1.30411122	-0.03564895	0.50756571
-0.81917159	6.86934866	-2.94885508	-2.59112241	0.7685491	-4.42047706	1.71605287	-1.15870153	-1.79002663	-1.40250224	-3.16637064	2.10767416
-0.63851402	2.07409352	-2.22680988	6.16227654	-2.46732398	1.94410217	-3.48711062	2.96110252	-3.18292664	1.5734566	-2.09690835	-0.64355447
-0.29454676	0.7812407	-0.75919314	1.60149947	-1.77479375	2.17398709	-0.77438117	0.69780671	-5.22022393	4.46199228	-2.43717408	0.77702455
-1.84631493	2.53764538	5.81837996	-7.60749081	-4.53213744	13.6462987	-2.05866688	-0.05676178	7.46863075	-7.93402522	4.13285699	0.14075296
1.04684684	-1.50182149	4.33427922	-4.12794235	-3.76186075	7.92784041	0.59329328	-0.1805969	2.26183087	-2.34394845	1.0305997	0.44455893
0.47339685	-0.62424981	0.15451129	1.58259262	-2.40064168	2.05788375	-1.13860869	1.35538858	-0.46251463	-0.32065111	-0.14017259	-0.28688234
0.9110378	-2.60322566	2.92968704	-5.17783881	3.80646265	-3.02631481	2.95884032	-2.34067446	1.84819814	-0.89788165	1.62660964	0.21461155
-4.48326539	4.89316264	3.05683198	-4.57556405	1.1841195	1.9977215	-7.37838262	-1.06188176	2.78032837	-2.10733874	0.29177222	0.23226624
0.1755558	0.06067824	-0.10749337	0.03411111	-0.27837617	1.11091706	-2.15752926	2.05394065	-0.35636532	-0.77718125	0.97472073	-2.36243236
0.37758818	-1.49185444	0.42664468	1.15622706	-5.27500286	5.7084342	-2.59388592	2.22746564	-3.34693984	2.46800341	-0.51882133	-1.33143961
-7.34807906	12.6840345	-2.41030865	6.64452895	-2.95240234	6.73098863	-5.76020208	0.08121115	-0.98228273	-1.46855952	-4.60009612	-0.37569491
3.30291795	2.16839958	-5.72636459	-0.11931877	-4.02212618	-2.00226927	1.93129804	-2.92911276	4.3908145	-5.18492694	4.3599799	-0.71159224
0.81562426	0.99256303	-1.36659991	-1.53291802	-3.99152802	4.17638652	1.16067154	1.72321608	-3.20728739	2.53740848	0.13319499	-0.4790475
6.49634741	-0.89460217	-3.79076927	9.94975229	-2.28669058	-1.44890577	-1.5212878	8.77888264	8.98274986	-16.5398272	8.94504789	-9.80979494
0.15863553	-0.65860845	0.17428416	-0.45416195	1.01793824	0.56966746	0.22338355	-0.22578726	1.61543558	-1.50180597	1.32052691	0.36313313

**Pesos 2da Capa (1x25)**

-2.46221922	1.38099908	3.28168755	1.3835818	2.72473259	0.61103081	...
...	-1.03270538	-4.64640727	0.32581298	1.94421614	0.43381566	...
...	-1.39760181	1.15582491	0.49697179	-1.01383087	3.54414757	...
...	1.5145772	0.45820923	-4.7828027	-1.14028724	-0.86997103	...
...	-0.91929791	4.81797139	-0.22592908	-4.70451595		

**Bias 1ra Capa (25x1)**

-4.27858655
1.82328256
2.31364875
5.97918796
-1.41689042
0.3006438
-0.91695129
-2.36065386
-0.94972532
1.65666344
-0.23062869
-1.50764856
-0.01588757
-1.48495619
-0.85188722
-0.15656709
-0.68369953
-1.40328556
2.23914067
-0.88875653
-9.63769081
5.20335233
-2.34416385
-4.99699823
1.81480465

**Bias 2da Capa (1x1)**

0.47245546
------------

**8.f. Velocidad de vientos alisios**

**Pesos 1ra Capa (24x12)**

0.31792805	0.48120253	0.46140542	-0.79354352	-0.07709975	0.99217409	-1.17736734	0.26210553	-1.4654163	-0.36680381	1.60411305	-1.60181832
0.5616709	-0.20439271	-1.16822211	1.17150836	-0.51532589	1.2778153	-2.11351592	1.0912153	-1.56277038	-0.02764422	0.81547863	-2.13875211
0.76356498	-0.25321283	-1.45150231	1.49549818	0.5589151	0.42731858	-0.26278263	1.04153671	-0.59033056	0.31411344	-0.66502351	-1.16578715
-0.52034418	-0.38686373	-1.52064929	-0.36601218	-0.19033979	-0.5863923	-1.04281708	1.99308496	1.32799788	0.29003393	-0.04117284	-0.07146738
-2.27271053	-0.10888145	2.22901711	-0.60808855	2.38003348	3.22050937	0.83229803	-0.29485134	-1.93004806	0.18956773	3.08607108	1.70303484
2.35156288	-1.50557454	-0.7202144	2.6207938	1.64091671	-1.21528377	-1.49320931	-1.69857671	1.6599702	-1.0478823	2.7673601	0.84860036
-2.3077321	-2.22139582	1.35605239	0.54570688	-2.87911081	-0.66612835	1.30645834	-4.04453133	-0.44765041	-1.48888315	-6.29899292	2.71704915
-0.03047939	-0.75107429	0.4867429	2.29145568	0.12190245	-0.30646059	-1.5025239	-1.11086127	1.11337497	-0.02313765	0.3035756	0.56963323
-0.58751371	1.88227954	-0.98473044	0.810402	-1.6762503	-0.48246656	-0.67505426	0.25047827	-0.63739416	-1.14867358	-0.55048926	0.08404597
-1.26031712	3.67841512	-0.77773865	-0.11631101	1.04893199	-0.69654794	-3.90397917	0.20259814	0.3481517	-0.92970353	1.19801325	-1.16005327
1.253878	2.32476401	-0.73905714	-1.39310711	-1.32903358	1.10024527	0.54478307	2.93256278	-3.69020256	-0.22807365	1.98244948	2.37738534
0.56615783	-0.77963527	-2.05088331	-1.27885526	-1.998285	-1.52109847	-1.02384042	2.51263177	1.73192084	0.07923341	-0.33227975	-1.43999351
1.44406408	1.65378095	-0.42287764	-0.86679627	-0.93480841	0.35250533	-0.31420887	4.09705688	-1.549771	0.09909704	1.08607409	-0.13061978
0.16850752	1.08331237	0.63761653	-2.76557948	1.08650138	0.05610991	-0.75980326	-0.71582331	-0.3232556	-0.18195858	1.34581947	-0.81926792
-0.23212095	-1.13692011	-1.32225751	-1.81996755	-2.31060001	-1.52993205	-0.25742958	1.96856773	0.90759384	-0.02996351	0.50862556	-1.77060592
-3.42266602	0.85536462	-2.70952374	2.83335544	-2.32189272	0.06575068	1.36462667	0.34227703	1.37381995	-4.22915226	3.60995528	-1.12468432
0.11696096	0.28868154	-1.5340091	1.20115367	5.25114537	4.0323353	0.15797191	-2.30882203	1.39124273	0.96814898	0.30181839	-3.38414677
4.52280378	5.04047095	-3.64786022	2.66213034	-3.87159308	0.12875608	-0.67269364	-0.54979342	-1.85742106	-7.94124918	-1.18801961	0.17105327
0.16125049	0.16645172	1.64916331	-2.55064311	2.27544687	0.14076682	0.89005566	-0.36650815	1.04552699	0.82402965	-0.27995883	1.73576536
-1.13451781	-1.69039533	3.17566599	-1.61817017	-0.86932268	0.12615705	-2.11240363	-0.48040258	1.55818516	0.48292716	2.09535356	1.33269511
-1.13490737	-0.77791822	-1.05438602	0.19800049	-0.36789625	-0.49402525	-0.24738944	1.46896196	1.08607392	0.631652	-0.47591926	0.66987662
-1.48947777	-0.79649789	0.83587699	0.16904237	0.14278302	1.46608856	-0.0151225	-0.32199039	-1.68753251	0.77784593	0.9236238	1.01931208
-1.01022395	-1.2498337	0.80457882	-0.00852446	-2.05029533	0.16701834	0.78875415	-1.09802287	0.15353508	-1.1154782	1.97680125	-0.54091693
-0.89052641	1.18574722	-0.08081579	-6.82544069	0.12431032	0.37063973	1.29764777	2.88222324	-4.50843142	1.94664457	1.58334536	-1.0938273



**Pesos 2da Capa (1x24)**

1.82056672	-1.66822195	2.88437083	2.40978207	-1.50421154	1.16554984	...
...	-0.49347336	-2.21686757	1.25071117	0.69772235	0.53590599	...
...	2.62392253	-1.02819818	-1.92203126	-2.61943878	-0.42237216	...
...	-0.56261862	-0.55886462	1.31442169	1.06369057	-2.89071343	...
...	1.79478899	0.89480704	-1.20976005			

**Bias 1ra Capa (24x1)**

-1.43051242
-1.49795168
-1.40130963
-1.68378742
-2.92051079
-3.13090477
-4.14494811
-1.44986656
0.03341607
-1.88903039
1.20115924
0.29380053
0.95094496
-1.27323295
0.00946228
0.62236631
-2.87183596
2.80304933
-0.68612253
3.05308258
-1.45729737
-1.59340438
-0.41412226
5.06590978

**Bias 2da Capa (1x1)**

1.23823081
------------