



UNIVERSIDAD CATÓLICA  
DE SANTIAGO DE GUAYAQUIL

**SISTEMA DE POSGRADO**  
**MAESTRÍA EN TELECOMUNICACIONES**

**TEMA:**

Aplicación de redes neuronales artificiales en la estimación del nivel de servicio en un CALLCENTER

**Autora**

María Cecilia Paredes Ponce

**Trabajo de titulación previo a la obtención del grado de**  
**Magister en Telecomunicaciones**

**TUTOR:**

**MSc. Manuel Romero Paz**

Guayaquil, 24 de Octubre de 2018



UNIVERSIDAD CATÓLICA  
DE SANTIAGO DE GUAYAQUIL

**SISTEMA DE POSGRADO**  
**MAESTRÍA EN TELECOMUNICACIONES**

**CERTIFICACIÓN**

Certificamos que el presente trabajo fue realizado en su totalidad por María Cecilia Paredes Ponce, como requerimiento parcial para la obtención del Grado Académico de Magíster en Telecomunicaciones.

**TUTOR**

---

**MSc. Manuel Romero Paz**

**DIRECTOR DEL PROGRAMA**

---

**MSc. Manuel Romero Paz**

Guayaquil, 24 de Octubre de 2018



UNIVERSIDAD CATÓLICA  
DE SANTIAGO DE GUAYAQUIL

**SISTEMA DE POSGRADO**  
**MAESTRÍA EN TELECOMUNICACIONES**  
**DECLARACIÓN DE RESPONSABILIDAD**

YO, **María Cecilia Paredes Ponce**

DECLARO QUE:

El Trabajo de Titulación “**Aplicación de redes neuronales artificiales en la estimación del nivel de servicio en un CALLCENTER**”, previa a la obtención del Título de **Magíster en Telecomunicaciones**, ha sido desarrollado respetando derechos intelectuales de terceros conforme las citas que constan en el documento, cuyas fuentes se incorporan en las referencias o bibliografías. Consecuentemente este trabajo es de mi total autoría.

En virtud de esta declaración, me responsabilizo del contenido, veracidad y alcance del Trabajo de Titulación referido.

Guayaquil, 24 de Octubre de 2018

LA AUTORA

---

María Cecilia Paredes Ponce



UNIVERSIDAD CATÓLICA  
DE SANTIAGO DE GUAYAQUIL

**SISTEMA DE POSGRADO**  
**MAESTRÍA EN TELECOMUNICACIONES**

**AUTORIZACIÓN**

Yo, **María Cecilia Paredes Ponce**

Autorizo a la Universidad Católica de Santiago de Guayaquil la publicación, en la biblioteca de la institución del Trabajo de Titulación de Maestría titulado, “**Aplicación de redes neuronales artificiales en la estimación del nivel de servicio en un CALLCENTER**”, cuyo contenido, ideas y criterios son de mi exclusiva responsabilidad y total autoría.

Guayaquil, 24 de Octubre de 2018

LA AUTORA

---

María Cecilia Paredes Ponce

# REPORTE URKUND

Documento: Proyecto Tesis - Version Final Concepto 2.0 agosto 2018.docx (ID4984476)

Presentado: 2019-08-25 22:20 (-05:00)

Presentado por: entandopitico\_7@notmail.com

Recibido: entando.pitico.ucag@analisis.orkund.com

Mensaje: Envío trabajo de examen completo. [Ver el mensaje completo](#)

1% de estos 34 páginas, se componen de texto presente en 4 fuentes.

SISTEMA DE POSGRADO MAESTRÍA EN TELECOMUNICACIONES

TDMA- Aplicación de redes neuronales artificiales en la estimación del nivel de servicio en un CALLCENTER

[Licenciada María Cecilia Paredes Ponce](#)

Trabajo de titulación previo a la obtención del grado de Magister en Telecomunicaciones

TUTOR: ING. Manuel Romero Piz

Sucre, agosto de 2018

SISTEMA DE POSGRADO MAESTRÍA EN TELECOMUNICACIONES

CERTIFICACIÓN Certificamos que el presente trabajo fue realizado en su totalidad por María Cecilia Paredes Ponce, como requerimiento parcial para la obtención del Grado Académico de Maestría en Telecomunicaciones. TITULO

Reporte Urkund al trabajo de titulación en Maestría de Telecomunicaciones, titulado: **Aplicación de redes neuronales artificiales en la estimación del nivel de servicio en un call center**, de la ingeniera **María Cecilia Paredes Ponce**, se encuentra al 1% de coincidencias.

## **AGRADECIMIENTOS**

A Dios por permitirme obtener un logro más en mi vida, dándome la fortaleza necesaria, al ser mi gran apoyo estando en todo momento junto a mí.

A todos los docentes y coordinadores de esta maestría y de manera especial al Ing. Manuel Romero por su valiosa colaboración durante el desarrollo y ejecución de este trabajo.

## **DEDICATORIA**

Dedico esta tesis a Dios por su amor infinito.

A mis padres César Paredes y Margarita Ponce, a mis hermanas Ma. Angélica, Ma. Dolores y Anita y a mis dos sobrinos, que por su amor incondicional han sido el pilar fundamental para la culminación de este trabajo.

A mis amigos y compañeros quienes compartieron sus conocimientos, alegrías y tristezas durante todo el periodo de la maestría, a todas aquellas personas que siempre estuvieron a mi lado apoyándome y lograron que éste sueño se haga realidad.



UNIVERSIDAD CATÓLICA  
DE SANTIAGO DE GUAYAQUIL

**SISTEMA DE POSGRADO**  
**MAESTRÍA EN TELECOMUNICACIONES**

**TRIBUNAL DE SUSTENTACIÓN**

f. \_\_\_\_\_

**MSc. Manuel Romero Paz**

TUTOR

f. \_\_\_\_\_

**MSc. Manuel Romero Paz**

DIRECTOR DEL PROGRAMA

f. \_\_\_\_\_

**MSc. Orlando Philco Asqui**

REVISOR

f. \_\_\_\_\_

**MSc. Luis Córdova Rivadeneira**

REVISOR



## INDICE GENERAL

<b>AGRADECIMIENTOS</b> .....	VI
<b>DEDICATORIA</b> .....	VII
<b>INDICE GENERAL</b> .....	IX
<b>INDICE DE FIGURAS</b> .....	XI
<b>INDICE DE TABLAS</b> .....	XII
<b>GLOSARIO DE TÉRMINOS</b> .....	XIII
<b>RESUMEN</b> .....	XIV
<b>ABSTRACT</b> .....	XV
<b>CAPÍTULO 1: DESCRIPCIÓN DEL PROYECTO.</b> .....	2
1.1. Introducción .....	2
1.2. Antecedentes .....	4
1.3. Planteamiento del problema .....	4
1.4. Objetivo General .....	5
1.5. Objetivos específicos .....	5
1.6. Hipótesis por defender .....	6
1.7. Metodología de investigación. ....	6
<b>CAPÍTULO 2: MARCO TEÓRICO</b> .....	8
2.1. Redes neuronales artificiales .....	8
2.2. Características de una RNA .....	14
2.3. Modo de operación de una RNA .....	16
2.4. Arquitectura de RNA .....	16
2.5. Topologías RNA .....	18
2.6. Metodología de predicción .....	22
2.7. Modelos de pronóstico .....	25
2.8. Series de Tiempo .....	27

2.9. Método de promedios móviles .....	29
2.10. Método de Winter.....	30
2.11. Métodos de Box-Jenkins [ARIMA].....	31
<b>CAPÍTULO 3: ANÁLISIS DEL DISEÑO Y RESULTADOS.....</b>	<b>34</b>
3.1. Definición del caso de estudio .....	34
3.2. Planteamiento de la serie de tiempo.....	35
3.3. Pronóstico por descomposición de serie de tiempo.....	39
3.4. Diseño de pronóstico por metodología de Winter .....	43
3.5. Diseño de la RNA para pronóstico del nivel de servicio. ....	46
3.6. Comparación de resultados y selección del mejor método.....	57
<b>CONCLUSIONES .....</b>	<b>60</b>
<b>RECOMENDACIONES.....</b>	<b>62</b>
<b>BIBLIOGRAFÍA .....</b>	<b>64</b>

## INDICE DE FIGURAS

Figura 2.1. Diagrama básico de la neurona. ....	9
Figura 2.2. Esquema básico de una neurona artificial. ....	12
Figura 2.3. Topología Perceptrón con 5 señales de entrada. ....	19
Figura 2.4. Ejemplo de topología Backpropagation de una RNA. ....	20
Figura 2.5. Ejemplo de topología de RNA Hopfield. ....	21
Figura 2.6. Ejemplo de Topología Kohonen. ....	22
Figura 2.7. Esquema de la clasificación de los pronósticos. ....	26
Figura 3.1. Gráfica de serie de tiempo del total de llamadas por días. ....	36
Figura 3.2. Gráfica de la primera parte de la serie de tiempo, sin valores atípicos. ....	38
Figura 3.3. Diagrama de Cajas por día de la semana. ....	39
Figura 3.4. Análisis estacional de las llamadas entrantes según el día de la semana. ....	40
Figura 3.5. Gráfica de descomposición de serie con pronóstico de valores. ....	40
Figura 3.6. Gráfica de validación de los datos. ....	42
Figura 3. 7 Muestra de la hoja de cálculo con los resultados del modelo de Winter. ....	43
Figura 3. 8 Gráfica de los valores reales de la red y el pronóstico del método de Winter de validación. ....	45
Figura 3. 9. Proceso para elaborar pronósticos mediante una RNA. ....	47
Figura 3.10. Resultados de la topología 12x6x1 de RNA en Solver. ....	51
Figura 3. 11. Gráfica de los valores reales y proyectados de la primera parte de la serie de tiempo, correspondientes a la etapa de entrenamiento. ....	56
Figura 3. 12. Gráfica de los valores reales y proyectados de los meses consecuentes, correspondiente a la parte de validación de datos. ....	57
Figura 3. 13. Gráfica comparativa de las predicciones obtenidas por los distintos métodos y los valores reales de la etapa de validación. ....	58

## INDICE DE TABLAS

Tabla 3.1. Índices estacionales de los días de la semana.....	41
Tabla 3.2. Errores de pronóstico de los 4 meses por el método de descomposición de serie de tiempo.....	42
Tabla 3. 3. Valores de los parámetros del método de Winter .....	45
Tabla 3. 4. Errores del pronóstico de 4 meses por el método de Winter .	46
Tabla 3. 5. Tipos de topología de RNA posibles.....	48
Tabla 3. 6. Pesos de la RNA culminado el entrenamiento.....	52
Tabla 3. 7. Resultado de los RMSE de las distintas topologías .....	55
Tabla 3. 8. Errores del pronóstico de 4 meses por el método de una red neuronal artificial.....	56
Tabla 3. 9. Calculo de RMSE y MAPE de los distintos modelos en la etapa de entrenamiento.....	59
Tabla 3. 10. Cálculo RMSE, MAPE y de coeficiente de correlación de los distintos modelos de pronóstico en la etapa de validación. ....	60

## GLOSARIO DE TÉRMINOS

RNA	Red Neuronal Artificial
RNB	Red Neuronal Biológica
BP	Back Propagation
AR	Auto Regressive
MA	Mobile Average
ARIMA	Autoregressive Integrated Moving Average
MAPE	Mean Absolute Percentage Error
RMSE	Root-Mean-Square Error

## RESUMEN

En el presente proyecto se realiza la construcción de una red neuronal artificial para pronosticar el grado o nivel servicio de un centro de llamadas o call center perteneciente a un proveedor de internet. Esta red se elabora con la finalidad de demostrar que a través de este tipo de modelo computacional se puede predecir el grado de calidad en el servicio de un call center, es decir, poder determinar la eficiencia de atención de los operadores en los futuros días en función a una base de datos del nivel de servicio en días previos. Se empieza por dar una descripción concisa de los modelos tradicionales de determinación o pronóstico de una variable, así como también, se detallan la composición y funcionamiento de las redes neuronales artificiales, tanto en sus topologías, algoritmos de aprendizaje, aplicativos en diferentes áreas y su utilidad en la actualidad. Posterior a esto se define el problema a resolver especificando el método a utilizar, los modelos de predicción, métodos de ajuste exponencial y diferentes topologías de redes neuronales artificiales para poder llegar a la solución deseada. Con estos aditamentos se implementa una red neuronal utilizando como interfaz MINITAB y como elemento de aprendizaje SOLVER, con la finalidad de ver en base a análisis comparativos los errores de estimación y las etapas de entrenamiento de los modelos asociados para este estudio.

**Palabras Clave:** MINITAB, SOLVER, REDES NEURONALES, PRONÓSTICO, CALLCENTER.

## **ABSTRACT**

In the present project the construction of an artificial neural network is done to determine the degree or level of service of a Call Center. This network is elaborated with the purpose of demonstrating that through this type of computational model the quality of the service in the Call Center can be predicted, that is, to be able to determine the efficiency of attention of the operators in function of the demand of calls that they enter. We start by giving a concise description of the traditional models of determination or prognosis of a variable, as well as detailing the composition and functioning of artificial neural networks, both in their topologies, learning algorithms, applications in different areas and their utility today. After this, the problem to be solved is defined by specifying the method to be used, the prediction models, exponential adjustment methods and different topologies of artificial neural networks in order to reach the desired solution. With these add-ons, a neural network is implemented using MINITAB as an interface and as a learning element SOLVER, with the purpose of seeing the estimation errors and the training stages of the associated models for this study based on comparative analyzes.

**Keywords:** MINITAB, SOLVER, NEURAL NETWORK, PREDICTION, CALLCENTER.

# **CAPÍTULO 1: DESCRIPCIÓN DEL PROYECTO.**

En el capítulo 1 se detallan las generalidades del proyecto a desarrollar y la metodología a seguir para poder obtener los resultados del estudio en base a los objetivos planteados.

## **1.1. Introducción**

Sin importar el call center que se quiera analizar, ya sea uno de soporte técnico o uno de cobranzas, ventas, etc., las empresas que cuentan con estos centros se enfrentan diariamente a duras decisiones con respecto a parámetros tales como, planificación de horarios, personal, producción y sobre todo en mantener políticas de calidad eficientes que permitan tener un panorama más amplio y definido de lo que se afrontará mes a mes. Siendo un amplio campo de estudio, el proyecto se enfoca en la predicción del grado o nivel de servicio de un call center perteneciente a una empresa de Telecomunicaciones, esta elección se debe a que en la actualidad las Telecomunicaciones cubren uno de los mayores mercados y manejan en mayor número estos centros, debido a la necesidad de un soporte continuo al usuario final.

Mediante el análisis de las variables previamente mencionadas, se podrá tener una idea del comportamiento futuro y una predicción de los valores que tendría el índice de nivel de servicio, permitiendo a la administración del call center tomar medidas correctivas con anticipación, para así mejorar el tiempo de contestación de las llamadas entrantes, obteniendo el grado o nivel de servicio deseado y necesario para una buena atención de una central telefónica. Es importante recalcar que este trabajo no se trata sobre la calidad de servicio prestado, sino sobre grado o nivel de servicio de las llamadas que recibe el call center.

La idea es poder implementar para estos indicadores dentro del call center, un modelo matemático que permita minimizar los errores, tanto en la



asistencia brindada telefónicamente, como en el porcentaje de contestación exitosa de las llamadas entrantes mediante la predicción del mismo. Esta idea será plasmada mediante herramientas computacionales que permitan detectar estos cambios en el modelo de predicción de estos procesos y así poder ajustar los parámetros de los mismos para que, como ya se mencionó, se minimice el porcentaje de error generado en el grado o nivel de servicio del call center.

En una empresa que cuenta con un call center es de vital importancia mantener el grado o nivel de servicio elevado, ya que se caracterizan por la atención que les brindan a sus usuarios. La mayoría de estas instituciones realizan sus predicciones en base a un modelo clásico, que se basa en un historial de 3 a 5 meses y que no siempre es confiable. Es por esto por lo que se presenta este trabajo, para en base a un sistema computacional y un esquema matemático para predecir de manera más acertada el nivel de servicio de la central telefónica.

Los métodos estadísticos de predicción tradicionales se basan muy frecuentemente en las metodologías Box-Jenkins, las cuales requieren un nivel alto de conocimiento de los modelos y adicionalmente se depende del tipo de datos, ya que, de forma general estos deben ser estacionarios y si no lo son, deben transformarse en tales para que puedan ser trabajados con este modelo. Dentro de los pasos a seguir, se analizan correlaciones, adecuaciones del modelo, errores de predicción, etc., con lo cual se puede tornar muy complejo el método de predicción. Sin embargo, al hacer uso de un software en base a redes neuronales artificiales, se puede predecir de mejor manera eventos o procesos dentro de un call center.

En lo que respecta a las redes neuronales artificiales, se las trata como un conjunto de reglas que intentan imitar el comportamiento y pensamiento del ser humano para poder tomar mejores decisiones, es decir, matemáticamente hablando, los coeficientes del modelo se podrán adaptar dinámicamente, lo que permitirá a su vez conseguir estimaciones con un error mucho más pequeño en comparación al obtenido con métodos

tradicionales. Se construirá una red neuronal artificial que permita pronosticar el nivel de servicio de un call center de soporte técnico.

## **1.2. Antecedentes**

En la actualidad, la atención mediante un call center es la opción más recurrente por el usuario en caso de alguna consulta o soporte, teniendo como consecuencia la congestión de llamadas. Las empresas con mayor uso de este medio de atención son las de Telecomunicaciones, reduciendo el campo, a los proveedores de internet, ya que estas deben ofrecer un soporte continuo hacia el cliente. En un manejo de call center pueden existir llamadas que pueden durar más de lo necesario reduciendo el número de llamadas atendidas, o muy cortas ofreciendo una atención superficial, siendo así caso de estudio el nivel del servicio de un call center de soporte.

Para poder minimizar el porcentaje de error generado en el grado o nivel de servicio del call center, se recurre a un análisis mediante redes neuronales artificiales, teniendo conocimiento de su desempeño muy importante como herramienta de predicción, procesamiento de datos, descifrar información en base a un buen algoritmo, clasificación de patrones, aproximaciones, entre otras características que, de una u otra forma han contribuido a ramas de la ciencia como biología, ingeniería, medicina, así como también en ámbitos empresariales, de medio ambiente, financiero, manufactura e incluso a nivel militar.

Es importante destacar que también se tienen aplicaciones un poco más avanzadas como en sistemas aeroespaciales, de automotores, bancarios, de defensa y de reconocimiento del habla, todos estos encaminados al mismo punto, el de poder tener un medio o conglomerado de reglas computacionales que permitan predecir o pronosticar un determinado suceso o proceso.

## **1.3. Planteamiento del problema**

En la actualidad, la atención mediante un call center es la opción más recurrente por el usuario en caso de alguna consulta o soporte, teniendo como consecuencia la congestión de llamadas. Las empresas con mayor uso de este medio de atención son las de Telecomunicaciones ya que estas deben ofrecer un soporte continuo hacia el cliente.

En un manejo de call center pueden existir llamadas que pueden durar más de lo necesario reduciendo el número de llamadas atendidas, o muy cortas ofreciendo una atención superficial, siendo así caso de estudio el nivel del servicio de un call center de soporte.

#### **1.4. Objetivo General**

Diseñar un modelo efectivo y eficiente basado en redes neuronales artificiales para estimar el nivel o grado de servicio a futuro.

#### **1.5. Objetivos específicos**

- Aplicar las redes neuronales para la determinación del grado de nivel o servicio de un call center de soporte perteneciente a un proveedor de internet, mediante un pronóstico basado en valores previos del nivel de servicio.
- Seleccionar la topología de red neural que se acople mejor al caso de estudio, y permita los mejores resultados con el fin de obtener el pronóstico más acertado de los valores, y presentar las correcciones adecuadas.
- Emplear los modelos Winter y descomposición de series de tiempo, para mediante un análisis comparativo determinar el método más eficiente en el estudio de las predicciones del índice del nivel o grado de servicio de las llamadas realizadas al soporte técnico de la empresa.
- Constatar la factibilidad del resultado obtenido a través de la aplicación de redes neuronales artificiales para el pronóstico

del nivel o grado de servicio en centrales de atención telefónica para brindar soporte técnico para a su vez optimizar la atención de las mismas.

#### **1.6. Hipótesis por defender.**

El sistema de redes neuronales artificiales permitirá manejar de mejor manera la gestión de llamadas dentro de la central telefónica, mediante algoritmos o métodos de predicción autodidactas o aprendizaje de máquina (machine learning) que, identificado el comportamiento del índice de nivel de servicio, se pueda corregir y mejorarlo en la siguiente ocasión y así ir construyendo una memoria de trabajo para la gestión de llamadas y la calidad del servicio de atención de las mismas.

#### **1.7. Metodología de investigación.**

La metodología de investigación a aplicar en el caso de estudio es descriptiva, tal que permita establecer las características del objeto de investigación, pronosticar el nivel o grado de servicio prestado por un call center de soporte en la actualidad, e identificar el comportamiento o rasgos futuros que permitan minimizar y corregir los errores para lograr un óptimo nivel de atención.

Durante la investigación se plantea un paradigma, el cual establece que un análisis mediante una red neural artificial permite obtener un pronóstico del grado o nivel de servicio de un call center, perteneciente a un proveedor de internet, logrando mediante esta herramienta computacional minimizar el error en el nivel de atención al cliente.

El proceso de estimación del nivel de servicio de las llamadas que ingresan a un Call center se debe seguir un cierto esquema de metodología para que la red neuronal en la que se basará este proceso de estimación tenga consistencia y sea fiel al propósito planteado en los objetivos, en base a esto se procederá como se describe a continuación.

El primer paso es poder escoger las variables independientes para el modelo neuronal que permita una correcta predicción del nivel de servicio en un centro de atención telefónica, esto en función de las variables de las cuales depende la calidad del servicio y el correcto manejo de las llamadas entrantes. Al tener conocimiento de cuáles son las variables que influyen en el nivel del servicio del call center, se logra establecer el tipo de investigación a realizar, sea experimental, pre-experimental o no experimental, el cual, en este caso al observar la influencia de las variables independientes sobre la dependiente, se define la investigación como un proyecto pre-experimental, en el cual se controla la variable dependiente para analizar su incidencia causal sobre la variable dependiente.

Una vez obtenidas las variables se utilizarán algoritmos matemáticos mediante series de tiempo para poder generar y encontrar patrones de entrenamiento y prueba, los cuales cimentarán las bases del modelo neuronal que se desea proponer.

Consecuentemente, estos patrones se deben escoger la correcta topología para la red neuronal artificial que se desea implementar, en función de cómo se vaya a implementar y cuáles son los resultados que se desea obtener del modelo a plantear.

Posteriormente mediante los algoritmos de predicción escogidos (en base a los patrones de entrenamiento y topología RNA) se podrá construir un sistema entrada/salida que permita obtener en base a las variables escogidas, un resultado que permita tener una idea del nivel de servicio brindado por la central telefónica y si se tiene algún error o nivel bajo de servicio, el mismo sistema RNA pueda encontrar la mejor forma de incrementar el nivel de satisfacción del servicio brindado.

## **CAPÍTULO 2: MARCO TEÓRICO**

El nivel o grado de servicio es uno de los principales indicadores utilizados para analizar la performance de un call center. Este parámetro representa el porcentaje de llamadas que son atendidas antes de una cierta demora fija. Al realizar un estudio enfocado en un call center, la primera opción es basarse en la teoría de colas, donde se aplican procesos para modelar la cola de espera de una llamada entrante a un call center mediante los modelos de Earlangs C y Earlangs A. (Capdehourat, 2006)


Sin embargo, en este proyecto se plantea la alternativa de implementar las redes neuronales artificiales para la predicción del grado de servicio en un call center, para lo cual es importante tener conocimiento de los fundamentos teóricos necesarios, los mismos que se detallan en esta sección junto con los métodos y modelos de predicción que permitirán tener una idea del funcionamiento y correcta aplicación de este tipo de modelo de predicción computacional. (Capdehourat, 2006)

### **2.1. Redes neuronales artificiales**

Para poder interpretar y comprender el comportamiento de las redes neuronales artificiales, es importante primero tener en claro lo que es la inteligencia artificial. La rama de la ciencia actual conocida como inteligencia artificial, representa el conjunto de técnicas que pretende establecer formas de imitación del comportamiento humano y de su inteligencia, todo a través de sistemas de cómputo. Dentro de los procesos que se imitan están el reconocimiento de patrones, diagnósticos, clasificación de objetos y situaciones y de forma particular la capacidad de poder imitar el comportamiento de las neuronas del cerebro, lo que se conoce como redes neuronales artificiales (Haugeland, 1996).

## Redes neuronales biológicas y artificiales

La neurona como unidad biológica, es un tipo de célula del sistema nervioso que tiene como principal función la de excitar eléctricamente su membrana plasmática. Las neuronas están especializadas en la recepción de estímulos y conducción de impulsos nerviosos, los cuales, en forma de potencial de acción, interactúan con otras neuronas y con otro tipo de organismo celulares como las fibras musculares de la placa motora (Flórez & Fernández, 2008).



**Figura 2.1. Diagrama básico de la neurona.**  
Fuente: (Flórez & Fernández, 2008)

En la Figura 2.1 se observa la composición esencial de una neurona biológica, en donde se destacan las dendritas, que son las ramificaciones que reciben los impulsos de otras neuronas y el axón que es el conducto de los impulsos nerviosos del cuerpo.

### Red Neuronal Biológica

Las redes neuronales biológicas (RNB), también conocidas como circuitos neuronales, son un conjunto de conexiones sinápticas producidas por la unión ordenada de neuronas en diferentes regiones, producto de la migración neuronal. Es importante destacar que el cono de crecimiento (estructuras móviles que exploran el ambiente extracelular), están controlados totalmente por los axones y el reconocimiento de las estructuras sinápticas, es decir, el cono de crecimiento detecta y da

respuesta a las moléculas que se usan para la señalización de retraimiento, giro o continuación, debido a que estas moléculas se usan para identificar las vías correctas y prohibir las vías incorrectas, todo esto para poder agilizar el proceso de formación de sinapsis (Izaurieta & Saavedra, 2014).

### **Red Neuronal Artificial**

Las redes neuronales artificiales (RNA) son parte de un modelo computacional, conformado con un conjunto de unidades neuronales simples o neuronas artificiales, las que simulan de manera análoga el funcionamiento de las neuronas en los cerebros biológicos. Con cada unidad neuronal artificial se tiene un enlace entre otras unidades neuronales adyacentes, con el fin de incrementar o suprimir el estado de activación de las adyacencias creadas entre dichas unidades. Cada unidad neuronal artificial funciona en base a una operación de suma, ya que puede existir una función de limitación o de umbral en cada enlace o unidad neuronal, por ende, la señal tendrá que superar dicho umbral para poder propagarse hacia otra unidad neuronal. Es importante destacar que estas redes o sistemas son autodidactas, ya que aprenden con cada acción que realice y se conforman a sí mismos a través de los diferentes enlaces que vayan formando, con lo que se excluye el método convencional de programación, el cual solo se basa en establecer soluciones o características de una situación o problema (Flórez & Fernández, 2008).

### **Semejanzas en las RNA y RNB**

De forma general, en ambos tipos de redes neuronales se tiene actividad sináptica (sinapsis), por lo que se debe tener en claro la similitud que existirá en este proceso en una RNA, tomando como base el modelo esencial de las RNB. En base a esto se considerarán como entradas a las señales que llegan al proceso de sinapsis, las cuales serán clasificadas en función de su importancia, es decir, serán atenuadas o amplificadas a través de un parámetro o peso asociado a la sinapsis que se está estableciendo.



Con estas señales de entrada del proceso de sinapsis se pueden excitar a las neuronas (peso positivo de sinapsis) o inhibirla (peso de sinapsis negativo), por lo cual el efecto final será la suma de las entradas ponderadas, por lo que si se tiene que la suma es igual o supera el valor del umbral la neurona se activa, es decir, se tiene una salida. El proceso detallado anteriormente es un todo o nada, la neurona se activa o no lo hace, dependiendo fundamentalmente de la actividad del sistema nervioso, ya que de esto depende la facilidad de transmisión de señales, siendo esta habilidad de ajustar las señales, todo un mecanismo de aprendizaje tanto para una RNA como para una RNB (Lafon, 2002).

En base a lo descrito las RNA deben buscar siempre 3 características que son fundamentales en una RNB, las cuales son:

**Adaptabilidad:** Corresponde a la capacidad que tienen las neuronas para poder cambiar sus enlaces, en función del nivel del estímulo y la respuesta que se quiera (Hilera & Martínez, 2000).

**Memoria Distribuida:** La memoria de la red neuronal se distribuye en cada una de las neuronas que la conforma, es decir, cada neurona tiene parte de la información necesaria para poder tener una respuesta en la salida (Hilera & Martínez, 2000).

**Procesamiento paralelo:** Las RNB tienen la capacidad de poder añadir y analizar mucha información al mismo tiempo (Hilera & Martínez, 2000).

Es en base a estas características, que las RNA pueden aprender y generalizar a partir de un conjunto de datos con una relación matemática que no se conoce. Existen muchas definiciones para las RNA, entre ellas se destacará la que indica que las redes neuronales artificiales se asemejan a un grafo dirigido que tiene que cumplir las siguientes características:

- Cada nodo  $i$  tiene una variable de estado  $y_i$ .

- Cuando existe una conexión  $(i,j)$  entre los nodos  $i$  y  $j$ , se le va a asociar un peso sináptico  $w_{ji}$ , el cual pertenece al conjunto de los números reales.
- Para cada nodo  $j$  se tiene un sesgo  $b_j$  perteneciente a los reales.
- Para cada nodo  $j$  se asigna una función de transferencia  $\Phi_j(y_i, w_{ji}, b_j)$ , la cual depende fundamentalmente del bias, el peso, las conexiones y los estados de los nodos  $i$  conectados a él, lo cual permitirá obtener un nuevo estado del nodo (Moya, Herrero, & Guerrero, 1998).




Figura 2.2. Esquema básico de una neurona artificial.  
Fuente: (Moya, Herrero, & Guerrero, 1998)

En la Figura 2.2 se destaca el funcionamiento y estructura de una neurona artificial de salida de una RNA. Se destacan los siguientes elementos:

$n$ : Iteración para la propagación del patrón del conjunto de entrenamiento de la RNA.

$y_j(n)$ : Salida de la neurona  $j$ .

$w_{ji}(n)$ : Peso asignado a la conexión de la entrada  $i$  en la neurona  $j$ .

$b_j(n)$ : Sesgo de la neurona  $j$ .

$v_j(n)$ : Valor de activación de la neurona  $j$ .

$\Phi_j$ : Función de transferencia de la neurona  $j$ .

$d_j(n)$ : Salida esperada de la neurona  $j$  cuando se propaga un patrón  $n$ .

$e_j(n)$ : Error de la salida de la neurona  $j$  cuando se ha propagado el  $n$ -ésimo patrón.

De lo hasta ahora descrito se destacan los nodos de entrada, que son valores escalares que se le dan a la red de acuerdo con el problema que se esté estudiando. Por otra parte, los nodos de salida son los valores que da como resultado la red luego del aprendizaje, así como también, los pesos sinápticos, los cuales son valores numéricos que permiten expresar numéricamente la importancia de la entrada que se esté trabajando. También es importante destacar el sesgo y las funciones de activación, ya que el sesgo es un valor que nace de una entrada fija e igual a 1 multiplicado por el peso  $W_{0k}$ , mientras que las funciones de activación son funciones lineales o no lineales que limitan el rango de salida de una neurona. Finalmente, y en base a lo detallado se debe tener presente que un algoritmo de entrenamiento de una RNA permite modificar el valor de los pesos en base a la siguiente expresión:

$$w_{ji}(n + 1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (2.1)$$

En donde  $\Delta w_{ji}(n)$  es un valor obtenido en base a una regla que define el algoritmo de entrenamiento que se utilice. Si  $e(n)$  es el error de la red cuando se está propagando el  $n$ ésimo patrón de entrenamiento, se tendrán dos posibles valores de probabilidad para medir el desempeño de la RNA, los cuales se los obtendrá en base a las siguientes expresiones:

$$e(n) = \frac{1}{2N} \sum_z^N \sum_j (e_j(n)^z)^2 \quad (2.2)$$

$$e(n) = \frac{1}{2} \sum_z^N e_j(n)^2 \quad (2.3)$$

Entonces con la expresión 2 se tiene la definición del error global de la RNA para todo el conjunto de aprendizaje y los  $N$  patrones, mientras que con la expresión 3 se tiene la definición del error medio cuadrático instantáneo de un patrón.

Por otra parte, se tiene que el algoritmo Back Propagation (BP) o propagación hacia atrás el cual hace uso de la expresión 3 para modificar  $w_{ji}(n)$  con respecto a  $e(n)$ , entonces se tiene:

$$\Delta W_{ji}(n) = \frac{\partial e(n)}{\partial w_{ji}(n)} \quad (2.4)$$

$$\Delta W_{ji}(n) = -\delta_j(n)y_i(n) \quad (2.5)$$

Entonces, si  $\delta_j(n)$  es un gradiente local y  $j$  es una neurona de la capa de salida se tiene:

$$\delta_j(n) = e_j(n)\Phi_j'(v_j(n)) \quad (2.6)$$

$$\delta_j(n) = \Phi_j'(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (2.7)$$

En la expresión 7 se tiene el gradiente local si la neurona  $j$  perteneciera a una oculta en la RNA. En base a lo descrito se puede afirmar que el algoritmo de propagación hacia atrás cambia de forma iterativa los pesos de las expresiones 5 y 6 hasta que los valores de las expresiones 2 y 3 alcancen un valor de tolerancia, es decir, que la red haya aprendido el conjunto de entrenamiento utilizado (Haykin, 1999).

## 2.2. Características de una RNA

Dentro del estudio de las RNA es de suma importancia conocer cuáles son las características distintivas para posteriormente implementar un modelo, entonces se tienen las siguientes particularidades:

**Aprendizaje inductivo:** Las RNA no tienen reglas o lineamientos establecidos para dar una solución, puesto que, mediante los métodos y ejemplos de aprendizaje se obtienen reglas propias para obtener una

solución y modifican estas reglas en función de la experiencia. Estas reglas se almacenan en las conexiones (Fuente, Gonzalez, Zamarreño, & Calonge, 1999).

**Generalización:** Una RNA entrenada puede representarse sin necesidad de hacer uso de los datos de aprendizaje, esto gracias a que la respuesta obtenida depende netamente del parecido de los datos con las secuencias de entrenamiento (Fuente, Gonzalez, Zamarreño, & Calonge, 1999).

**Abstracción o toleración al ruido:** Las RNA tienen la facultad de abstraer las características esenciales de las secuencias de entrada, de forma que pueden procesar datos corruptos (incompletos o distorsionados) (Fuente, Gonzalez, Zamarreño, & Calonge, 1999).

**Procesamiento Paralelo:** Las RNA de manera inherente cuentan con un paralelismo en su procesamiento, esto ya que tanto su estructura como el modo de operación les permite un procesamiento paralelo real (como una neurona biológica) mediante multiprocesadores computacionales (Pino, Gómez, & Abajo, 2001).

**Memoria Distribuida:** Las RNA van acumulando conocimiento en sus diferentes conexiones durante el proceso de aprendizaje y entrenamiento, esto permite tener tolerancia a posibles fallos que se pudieran presentar por destrucción de neuronas o de conexiones entre las mismas. Es importante resaltar el hecho de que la información está distribuida en toda la red, pero en programas convencionales los fallos pueden dar como resultados datos absurdos o simplemente no dar resultados (Pino, Gómez, & Abajo, 2001).

En base a estas características se debe aclarar el hecho de que las RNA pueden tener factores de peso fijos, es decir, tener una tarea preestablecida o en su defecto tener factores de peso variables que implica que las reglas de aprendizaje se ajustan en función de la fuerza de conexión con otras neuronas, lo que hace a los pesos variables un aditamento importantísimo

si es que de manera previa no se conoce cuál debería ser su valor correcto (Pino, Gómez, & Abajo, 2001).

### **2.3. Modo de operación de una RNA**

En cualquier tipo de red neuronal se tiene una fase previa de aprendizaje, posteriormente y de forma opcional una fase de prueba y la fase de aplicación o recuperación de lo aprendido. La fase de aprendizaje puede realizarse de tres formas descritas a continuación:

**Aprendizaje supervisado:** Es el método de aprendizaje más sencillo en una RNA el cual consiste básicamente en la presentación de patrones de entrada junto con los de salida deseados para cada uno de los patrones de entrada, es decir, a cada patrón de entrada se le asocia un patrón esperado de salida (Haykin, 1999).

**Aprendizaje no supervisado:** Es el método de aprendizaje en donde no se muestra a la red los patrones de salida deseados, es decir, la red seguirá alguna regla de auto organización (Haykin, 1999).

**Aprendizaje reforzado:** Es el método de aprendizaje en donde el supervisor se limita a indicar si la salida brindada por la RNA es válida o no, es decir, o indicará cual debería ser la respuesta (Haykin, 1999).

### **2.4. Arquitectura de RNA**

Las arquitecturas de las RNA se basan en la estructura que va a tener la red, es decir, el modelo que seguirá. Este modelo o estructura tiene algunos componentes básicos que permitirán tener una idea de cómo se interrelacionarán las neuronas. Es importante indicar el hecho de que tanto el algoritmo de aprendizaje como la arquitectura están sumamente relacionados con la arquitectura de la RNA (Anthony & Bartlett, 1999). Los componentes del modelo son:

**Entradas:** corresponden a la vía o canal de alimentación principal que tendrá la RNA, este debe ser preestablecido en términos de cuantas entradas se desea tener y estas a su vez deberán ser estandarizadas o escaladas de acuerdo con el tipo de dato que ingrese. Procesar la información de entrada se puede realizar con algún tipo de método estadístico de exploración de datos para poder convertir los datos originales en un conjunto de datos que permita mejorar el desempeño de la red neuronal a diseñar (Anthony & Bartlett, 1999).

**Capas ocultas o intermedias:** corresponden al segmento de la red neuronal que de forma intermedia (ubicado entre la entrada y salida) contiene neuronas que realizan el trabajo de resolver el problema en base a las entradas que se tenga. Comúnmente una sola neurona no puede realizar este proceso por lo que se tiene un conjunto de las mismas, que al operar en paralelo conforman una capa, incluso ciertas redes neuronales artificiales requieren de más de una capa para resolver el problema ya sea este no lineal o completo, en donde se requerirá una mayor cantidad de capas para poder generar un correcto funcionamiento de la RNA. Es importante destacar que tanto el número de capas, neuronas como el número de todos que componen la red deben ser especificados en la arquitectura previo a la implementación o simulación de la RNA (Anthony & Bartlett, 1999).

**Salidas:** corresponden a las neuronas y nodos de salida de la red neuronal. El número de salidas dependerá del tipo de problema a resolver. La salida tendrá que ser descrita en la misma escala de los datos de entrada o los datos originales, es decir, si se utilizó algún proceso de escalamiento se deberá regresarlo a la escala original para que pueda ser representado correctamente en la salida de la RNA.

**Interconexión:** corresponden a los enlaces entre las capas de la red neuronal artificial, estas interconexiones se clasifican en:

- **Totalmente conectadas:** cuando la salida de una neurona de la capa  $i$  es la entrada para todas las neuronas de la siguiente capa ( $i+1$ ).
- **Localmente conectadas:** cuando la salida de una neurona de la capa  $i$  es la entrada para una región de neuronas de la siguiente capa ( $i+1$ ).

**Dirección:** corresponde a la ruta que sigue la información de las redes neuronales, estas se clasifican en (Anthony & Bartlett, 1999):

- **Redes de alimentación adelantada:** redes en donde las salidas de las neuronas de una capa solo pueden propagarse a las neuronas de la siguiente capa, es decir, la información solo viaja de la entrada hacia la salida.
- **Redes retroalimentadas:** redes en donde las salidas de las neuronas de una capa pueden ser las entradas de las neuronas de las capas anteriores.
- **Redes de alimentación lateral:** redes en donde las salidas de las neuronas pueden ser las entradas de las neuronas de la misma capa.
- **Redes recurrentes:** redes en donde existen lazos cerrados.

## 2.5. Topologías RNA


La topología de una red neuronal artificial hace referencia al número de elementos de procesamiento que forman la red y la cantidad de interconexiones existente entre ellos. A continuación, se detallarán algunos tipos de topologías (Martin Del Brio & Sanz, 2006).

### Topología Perceptrón

La topología perceptrón es en sí una red con una capa de salida de  $n$  neuronas y otra capa de salida con  $m$  neuronas en donde se hacen uso de señales binarias en entrada/salida y su función de activación es de tipo signo, es decir, si la sumatoria del producto del peso de la conexión con la entrada es mayor al umbral establecido, se toma el valor de uno, mientras



que en el caso contrario (menor o igual al umbral) es igual a 0 (Martin Del Brio & Sanz, 2006).



**Figura 2.3. Topología Perceptrón con 5 señales de entrada.**  
Fuente: (Martin Del Brio & Sanz, 2006)

En la Figura 2.3 se muestra un ejemplo de topología perceptrón en donde se tienen 5 señales de entrada y a través de un punto de unión sumadora, esa señal pasa a través de la función de activación y se obtiene la salida de la RNA.

### **Topología Backpropagation**

La topología backpropagation o topología de propagación hacia atrás hace uso de un algoritmo de aprendizaje supervisado en donde se hace uso de un ciclo de propagación adaptado a dos fases. Una vez que se tenga un patrón aplicado en la entrada de la RNA, este patrón se propaga desde la primera capa a través de las capas de las siguientes redes, hasta que se genere una salida. La señal de la salida se comparará con la salida deseada y se calculará una señal de error para cada una de las salidas que se tenga (Martin Del Brio & Sanz, 2006).




Figura 2.4. Ejemplo de topología Backpropagation de una RNA.


Fuente: (Martin Del Brio & Sanz, 2006)

En la Figura 2.4 se tiene un claro ejemplo de lo descrito en el párrafo anterior para la topología backpropagation. Se tiene una red totalmente conectada en donde se tiene alimentación adelantada y aprendizaje supervisado donde como principal característica se muestra una combinación de neuronas perceptrón ubicadas en capas.

### Topología Hopfield

La topología Hopfield es una red recurrente en donde todas las neuronas están conectadas entre sí, pero no con ellas mismas, es decir, se tiene una conexión irreflexiva. En esta topología la conexión de las neuronas es tal que cada neurona recibe señales de todas las demás y a su vez emite señales hacia todas ellas, pero no se auto estimula.

En este tipo de topología los pesos de los enlaces entre las neuronas deben ser necesariamente simétricos y una neurona no puede tener una conexión consigo misma, es decir:  $w_{ij}=w_{ji}$   $i \neq j$  tal que  $w_{ii}=0$ , ya que de esta forma la matriz de pesos  $\mathbf{W}$  es simétrica con el valor de 0 en la diagonal principal (Martin Del Brio & Sanz, 2006).




**Figura 2.5. Ejemplo de topología de RNA Hopfield.**  
**Fuente:** (Martin Del Brio & Sanz, 2006)

En la Figura 2.5 se tiene un ejemplo de la topología Hopfield en donde se observa una red recurrente en donde las neuronas no tienen enlaces consigo mismas, pero si entre todas ellas lo que permite que aprenden a reconstruir los patrones de entrada que memorizaron durante la etapa de entrenamiento.

### Topología Kohonen

En esta topología se tiene una red totalmente conectada y con alimentación adelantada en donde el aprendizaje es no supervisado. El objetivo que se tiene con la topología Kohonen es demostrar que un estímulo externo (datos de entrada) suponiendo que tenga una estructura propia y una descripción funcional del comportamiento de la red neuronal, es capaz por si solo de forzar la formación de mapas, es decir, formación de capas bidimensionales (Martin Del Brio & Sanz, 2006).

En esta topología las unidades de entrada reciben los datos normalizados de forma continua en donde a su vez, se normalizarán los pesos de las conexiones de la capa de salida para que concuerden a la misma escala de los datos de entrada. Finalmente, tras el proceso de aprendizaje de la red, cada patrón de entrada podrá activar una única unidad de salida.



**Figura 2.6. Ejemplo de Topología Kohonen.**  
**Fuente: (Martin Del Brio & Sanz, 2006)**

En la Figura 2.6 se muestra un ejemplo de la conexión de las neuronas en una RNA con topología Kohonen, en donde se observa que todas las neuronas de entrada están conectadas con todas las neuronas del mapa de resultados (capa bidimensional de salida).

## 2.6. Metodología de predicción

Para el caso de estudio del presente documento se hará uso del método de predicción en base a un modelo univariable en series de tiempo para las RNA. Se deben seguir una serie de pasos para construir, entrenar y probar que una RNA pueda predecir valores futuros de una serie de tiempo, basándose únicamente en sus valores pasados, entonces se tiene (Hanke & Wichern, 2006):

### Paso 1: Escalamiento de los datos

Como primer paso se debe de transformar los datos de entrada a valores entre 0 y 1 haciendo uso de la expresión (8) para la normalización de los datos, la cual se detalla a continuación:

$$z_t = \frac{y_t - Min}{Max - Min} \quad (2.8)$$

En donde:

$y_t$  → Corresponden a todos los valores originales de la serie de tiempo.

**Min y Max** → Corresponden a los valores máximos y mínimos de la serie de tiempo.

$z_t$  → Corresponden a los valores de la serie de tiempo transformada en valores entre 0 y 1.

## **Paso 2: Patrones de entrenamiento y patrones de prueba**

Como segundo paso se debe manejar la información que se tiene con los patrones de entrenamiento y de prueba, ya que, los valores de las series de tiempo se dividen en los datos de los patrones de entrenamiento y los datos de los patrones de prueba que corresponden al 80% y 20% de los datos respectivamente. Los datos de los patrones de entrenamiento son utilizados para entrenar a la RNA en el proceso de aprendizaje y los datos de los patrones de prueba se utilizan para evaluar la capacidad de generalización o de predicción de la RNA (Hanke & Wichern, 2006).

## **Paso 3: Topología de la RNA**

Para la topología de la red neuronal artificial se deben considerar los siguientes parámetros:

- Direccionamiento de la información: alimentación adelantada.
- Tipo de conexión entre neuronas: totalmente conectadas.
- Número de entradas: p
- Número de capas ocultas: 1
- Número de nodos en la capa oculta: q
- Número de salidas: 1
- Función de activación de nodos de capa oculta: función tangente hiperbólica.
- Función de activación de la salida de la red: función lineal.

#### **Paso 4: Definición de las entradas de la RNA**

Las entradas de la RNA se representarán con 'p'. Para poder seleccionar las entradas de la RNA se toman en cuenta las siguientes consideraciones (Hanke & Wichern, 2006):

- Periodicidad de datos: Dado que, para el caso de estudio del nivel de calidad de servicio en un Callcenter, la información de las series de tiempo es diario, por lo que se tomarán 5 retrasos.
- Pruebas de ensayo y error: Se pueden diferentes retrasos 5, 10, 15,..., según se crea conveniente para poder tener mayor precisión al momento de escoger la mejor topología de la RNA.

#### **Paso 5: Definición de la cantidad de nodos de capa oculta**

La cantidad de nodos de capa oculta serán representados con 'q'. Para poder definir la cantidad de nodos de la capa oculta se asume que el valor inicial del número de nodos de capa oculta es igual a la raíz cuadrada del producto de las entradas y salidas ( $m$  y  $n$  respectivamente), regla común en redes AD HOC. Con esto se tendrá una medida del parámetro de interés. Es importante recordar que mediante pruebas de ensayo y error se pueden agregar más nodos y así poder comparar los errores de ajuste y de predicción, con lo que finalmente se podrá tener una medida cierta de la cantidad de nodos de capa oculta que mejor se ajuste al modelo a desarrollar (Hanke & Wichern, 2006).

#### **Paso 6: Algoritmo de entrenamiento**

Como algoritmo de entrenamiento se utilizará el de backpropagation, el cual, como se mencionó en secciones anteriores consiste en una red con arquitectura en niveles y conexiones estrictamente hacia adelante entre las neuronas y hace uso de un aprendizaje supervisado.

### **Paso 7: Selección de los pesos iniciales**

El proceso de selección de los pesos iniciales es vital y crucial durante la construcción de la RNA por lo que es recomendable utilizar varios conjuntos de valores iniciales hasta conseguir buenos resultados y escoger el conjunto de valores que brinde el menor promedio entre la raíz de cuadrados de los errores del ajuste y la predicción (Hanke & Wichern, 2006).

### **Paso 8: Entrenamiento de la RNA seleccionada**

El proceso de entrenamiento es uno de los pasos esenciales dentro de la metodología del proceso de predicción del modelo de RNA ya que para esto se requiere establecer un máximo de ciclos, que error se tendrá como umbral de convergencia y cuál será la tasa de aprendizaje. Una vez definido esto se tendrá establecida la RNA con su respectiva ecuación la cual a su vez generará los valores de la serie de tiempo ajustada o producido por la RNA, haciendo uso de los patrones de entrenamiento ya descritos (Hanke & Wichern, 2006).

### **Paso 9: Predicción**

Como último paso se realizará la predicción del modelo de RNA planteado, en este proceso se obtendrá el valor de predicción  $t+1$  a través de la ecuación de la RNA definida previamente. Es importante destacar el hecho de que si se desean obtener predicciones más allá del periodo  $t+1$  se debe utilizar como entrada el periodo previo, es decir,  $t+1$  sería la entrada para producir la predicción  $t+2$ , y así sucesivamente, tomando en cuenta que se debe calcular el respectivo error de predicción (Hanke & Wichern, 2006).

#### **2.7. Modelos de pronóstico**

De manera general el pronóstico se considera el proceso mediante el cual se realiza una estimación anticipada del valor que pueda tener una variable

en base a condiciones específicas en un período de tiempo determinado (Hanke & Wichern, 2006).

Los pronósticos se los puede clasificar en base a algunos criterios, a continuación, se detallan los que se consideran más relevantes para el desarrollo del presente proyecto: En la Figura 2.7 se muestra un esquema sencillo de clasificación del pronóstico, en donde los pronósticos por plazo son a corto, medio o largo plazo. Por otra parte, los pronósticos pueden ser cualitativos o cuantitativos según el procedimiento que se utilice, así mismo, pueden ser clásicos o no clásicos en función del método para pronosticar. Finalmente, según el entorno del pronóstico pueden ser micro o macro (Ludlow, 1999). En base a lo ya descrito los modelos de pronóstico se basan en esta clasificación y a su vez por el tipo de método matemático que se utilice para calcularlo, como, por ejemplo, método de regresión lineal múltiple, regresión exponencial, entre otros.




Figura 2.7. Esquema de la clasificación de los pronósticos.  
Fuente: (Ludlow, 1999)



## 2.8. Series de Tiempo

Las series de tiempo son secuencias cronológicas de valores de que una variable toma de forma particular. Estos valores son representados de la siguiente manera:

$$y(t_1), y(t_2), y(t_3), \dots, y(t_n) = y(t); t \in T \subseteq R$$

Es importante destacar el hecho de que si  $T=Z$  la serie de tiempo se convierte en discreta mientras que, si  $T=R$  la serie de tiempo es continua. Por otra parte, cuando  $t_i - t_{i-1} = k$  para todos los valores que pueda tomar el índice  $i$  hasta  $n-1$ , la serie de tiempo es equiespaciada, caso contrario, es una serie no equiespaciada (Peña, 2010).

### Descomposición de series de tiempo

Durante el proceso de descomposición de una serie, se debe analizar los parámetros de la misma, para esto se debe graficar la serie, para de esta forma encontrar los patrones, componentes y demás aditamentos que sean útiles en el proceso de predicción. Tomando en cuenta esto se describen a continuación los componentes de una serie de tiempo (Peña, 2010).

- **Tendencia T (t):** La tendencia o cambios en la media de la serie de tiempo hace referencia al componente de largo plazo que representa ya sea el crecimiento o disminución en la serie de tiempo en un periodo de tiempo amplio.
- **Ciclo C (t):** El ciclo hace referencia al movimiento ascendente o descendente de la forma de onda de la serie alrededor de la tendencia que esta tenga. Es importante denotar que los patrones cíclicos en los datos tienden a repetirse cada dos o 3 años, incluso más.
- **Variación estacional S (t):** La variación estacional hace referencia al patrón periódico que sucede y se repite cada cierto tiempo.

- **Componente irregular  $A(t)$ :** Como su nombre lo indica es el parámetro de la serie de tiempo que no sigue un patrón específico o regular e incluso reconocible, es decir, el componente irregular representa lo que resta luego de la tendencia, el ciclo y la variación estacional.

Entonces en base a lo descrito, se tienen tres tipos de series de tiempo, que pueden explicar claramente la relación entre los componentes de los datos observados. Suponiendo que:

**$Y(t)$**  representa la serie observada en un instante  $t$

**$T(t)$**  representa la componente de tendencia

**$C(t)$**  representa el componente cíclico

**$S(t)$**  representa el componente estacional

**$A(t)$**  representa el componente aleatorio o accidental

- Modelo aditivo:  $Y(t) = T(t) + C(t) + S(t) + A(t)$
- Modelo multiplicativo:  $Y(t) = T(t) \cdot C(t) \cdot S(t) \cdot A(t)$
- Modelo mixto:  $Y(t) = T(t) \cdot C(t) \cdot S(t) + A(t)$

### **Estimación de tendencia**

Dentro del proceso de análisis de una serie de tiempo es importante tener una medida de la estimación de la tendencia de la serie, para esto se suaviza la serie, es decir, a partir de la serie en la que se trabaja, se definirá una nueva serie que suavice los efectos externos a la tendencia como la estacionalidad, aleatoriedad, etc., de tal forma que se pueda encontrar la dirección de la tendencia (WeddingII & Cios, 1996).

### **Estimación de estacionalidad**

La estacionalidad de una serie de tiempo es la variación periódica y predecible de ella en un periodo inferior o igual a un año, siendo así, la estacionalidad es una componente de la serie de tiempo que se contrapone

con la tendencia y la variación cíclica. En base a esto, la estimación de este parámetro no solo tiene como objetivo adicionarla al modelo de predicción, sino que también permitirá al estimarla, lograr suprimirla de la serie de tiempo para poder observar las otras componentes ya mencionadas, incluyendo la componente irregular ya que esta puede ser confundida o malinterpretada en las fluctuaciones estacionales. Entonces planteando estos parámetros en un modelo clásico para  $T(t)$  se tiene lo siguiente (WeddingII & Cios, 1996):

$$Y(t) - T(t) = S(t) + C(t) + A(t) \quad \text{Aditivo}$$

$$\frac{Y(t)}{T(t)} = S(t) \cdot C(t) + \frac{A(t)}{T(t)} \quad \text{Mixto}$$

Entonces si a nivel de la serie de tiempo no se tiene tendencia se espera lo siguiente:

$$\forall t, T(t) = 0 ; \text{para modelos aditivos}$$

$$\forall t, T(t) = 1 ; \text{para modelos mixtos}$$

## 2.9. Método de promedios móviles

El método de promedios móviles es una técnica muy utilizada para el cálculo de pronósticos rápidos o de corto plazo en donde se calculan valores promedio en base a los datos históricos que se tengan disponibles y se usa este promedio para hacer pronósticos de un periodo futuro (Faraway & Chatfield, 1998).

El método de los promedios móviles se fundamenta en el hecho de que existe un patrón básico de comportamiento en los valores que toman las variables a pronosticar y que los datos históricos que se usen tienden a representar un modelo básico de comportamiento y a un modelo de fluctuaciones aleatorias. Es importante tomar en cuenta que para poder eliminar esta aleatoriedad en los datos que se obtengan se debe considerar el promedio de los últimos valores observados ya que estos, al usarlos

como pronóstico para un periodo próximo disminuyen la posibilidad de la componente aleatoria dentro de la predicción. El número de observaciones o datos observados se deben especificar con anticipación y mantenerse constante durante todo el proceso (Faraway & Chatfield, 1998).

Entonces en base a lo descrito para el método de promedios móviles se tiene como objetivo eliminar o atenuar de la serie de tiempo todos los componentes estacionales y los componentes irregulares que esta tenga, haciendo uso de la siguiente expresión:

$$Z_t = \frac{Y_{t-1} + Y_{t-2} + Y_{t-3} + \dots + Y_{t-n}}{n}$$

Tomando en cuenta que:

**Z<sub>t</sub>**: Corresponde al valor del pronóstico para el periodo siguiente.

**Y<sub>t-1</sub>**: Corresponde al valor real en el periodo t-1.

**n**: Corresponde al número de términos que tiene el promedio móvil.

## **2.10. Método de Winter**

La metodología de Winter se basa en realizar en realizar una atenuación exponencial ajustada a la tendencia y variación estacional. El método pondera los datos anteriores de la serie de tiempo, con parámetros decrecientes, asignando mayor peso a la información más reciente.

El modelo de atenuación exponencial lineal y estacional de tres parámetros de Winter, hace uso de una constante de atenuación para las estimaciones de los valores de tendencia (enfoque de Brown); una ecuación para atenuar en forma directa la tendencia y la pendiente empleando diferentes constantes de atenuación para cada una de ellas (modelo de Holt); y una ecuación adicional para determinar la estacionalidad.

Este método proporciona una forma fácil de explicar la estacionalidad en un modelo, cuando los datos tienen un patrón estacional (Hanke E., Reitsch G., 1996).

Las ecuaciones que se emplean para el planteamiento y diseño del modelo de Winter son:

- $A_t = \alpha \frac{Y_t}{S_{t-L}} + (1 - \alpha)(A_{t-1} + T_{t-1})$ ; la serie exponencial atenuada.
- $T_t = \beta(A_t - A_{t-1}) + (1 - \beta)T_{t-1}$ ; la estimación de la tendencia.
- $S_t = \gamma \frac{Y_t}{A_t} + (1 - \gamma)S_{t-L}$ ; la estimación de la estacionalidad.
- $F_t = (A_t - T_t)S_{t+1}$ ; pronósticos de los valores utilizados para el diseño.
- $F_{t+p} = (A_t - pT_t)S_{t-l+p}$ ; pronóstico de p periodos en el futuro.

Donde cada parámetro tiene el siguiente significado:

- $A_t$ = nuevo valor atenuado
- $\alpha$ =constante de atenuación ( $0 < \alpha < 1$ )
- $\beta$ =constante de la atenuación de la estimación de tendencia ( $0 < \beta < 1$ )
- $T_t$ =estimación de la tendencia
- $\gamma$ =constante de atenuación de la estimación de la estacionalidad ( $0 < \gamma < 1$ )
- $S_t$ =estimación de la estacionalidad
- $p$ =periodos a estimar en el futuro
- $L$ =longitud de la estacionalidad

La atenuación exponencial es una técnica popular debido a su simplicidad y bajo costo, sin embargo, presenta mejores resultados para la estimación de pronósticos de corto plazo.

## 2.11. Métodos de Box-Jenkins [ARIMA]

La metodología de Box-Jenkins ARIMA (Modelo autorregresivo integrado de media móvil) es un método de análisis para series de tiempo con un enfoque de modelado iterativo de 3 etapas, las cuales se detallan a continuación (Eppen, Gould, Schmidt, Moore, & Weatherford, 2000), (Collantes & Rivas, 2002).

- **Etapa 1:** Identificar y seleccionar el modelo es el primer paso dentro de este método en donde se debe asegurar que las variables a utilizar sean estacionarias. Para poder determinar qué modelo utilizar, si el de promedio autorregresivo (AR) o el de promedio móvil (MA), se debe identificar la estacionalidad de la serie dependiente y hacer uso de los gráficos de las funciones de autocorrelación y autocorrelación parcial de la serie de tiempo.
- **Etapa 2:** Estimar los parámetros del modelo haciendo uso de algoritmos de cálculo que permitan obtener los coeficientes que se ajusten de mejor manera al modelo ARIMA seleccionado. Dentro de estos métodos, los más utilizados son el de máxima verosimilitud o mínimos cuadrados no lineales.
- **Etapa 3:** Consiste en la comprobación del modelo escogido mediante prueba y error si el modelo estimado, se puede ajustar adecuadamente a las características de un proceso invariado estacionario, es decir, los residuos deben ser independientes entre ellos y la media y varianza deben ser constantes en el tiempo. Es importante resaltar que, si la estimación no es la adecuada, se debe realizar nuevamente el proceso desde la etapa 1.

Dentro de lo descrito entonces se detalla a continuación los modelos univariantes de series temporales:

$$Y_t = f(Y_{t-1}, Y_{t-2}, \dots) + a_t$$
$$Y_t = \hat{Y}_t + a_t$$

Sabiendo que:

$Y_t$ : Corresponde a la serie de tiempo trabajada.

$\hat{Y}_t$ : Corresponde a la componente predecible.

$a_t$ : Corresponde al componente aleatorio o ruido blanco.

Con esto se tienen dos enfoques, el primero es obtener la serie observada postulando a  $\hat{Y}_t$  como la parte predecible, o el segundo enfoque, el cual consiste en obtener  $a_t$  sabiendo que este parámetro es la parte no predecible.

En base a esto, se debe recalcar que este método y la solución que brinde las redes neuronales artificiales en conjunto con los métodos clásicos de predicción de series de tiempo serán puestos en comparación para dar solución al problema planteado en el presente proyecto. Como ya se mencionó anteriormente el modelo ARIMA hace referencia al método o proceso autorregresivo integrado de promedio móvil o método univariante de Box Jenkins requiere de una serie estacionaria, si la serie no lo es, se puede convertirla en una utilizando el método de diferenciación (Eppen, Gould, Schmidt, Moore, & Weatherford, 2000).

## **CAPÍTULO 3: ANÁLISIS DEL DISEÑO Y RESULTADOS**

En esta sección se detallarán los resultados obtenidos y el proceso a seguir para la implementación de la red neuronal artificial que permita medir la calidad de servicio en un CALL CENTER; se elaborará predicciones mediante distintas metodologías y así poder realizar una comparación entre los procesos sencillos de predicción y la elaboración de una red neuronal.

### **3.1. Definición del caso de estudio**

Como se indica previamente, el estudio se enfoca en la predicción del grado o nivel de servicio de un call center en el área de las Telecomunicaciones, donde su actividad principal es proveer internet a hogares y pequeñas y grandes empresas alrededor de todo el país. Para fines del estudio se llamará a la empresa "ProveedorA", la cual maneja un call center para ofrecer soporte a los usuarios finales.

A medida que transcurría el tiempo, incrementaban los clientes y con ello las llamadas entrantes al call center de soporte y en el ProveedorA se empezaron a presentar problemas con los indicadores de atención al cliente. La insatisfacción de los consumidores se basaba en que las llamadas realizadas a soporte no ingresaban o se demoraban en ser atendidas, dejando como resultado una notoria caída en el grado de atención y nivel de servicio, siendo los resultados un grado de atención de 88% cuando la meta es 95% y nivel de servicio en 54% cuando el objetivo es 82%, valores que finalmente ocasionaron pérdida de clientes, ya que no solo busca un buen producto sino también una ayuda, guía o soporte en caso de algún inconveniente.

En base a esta baja en la demanda del servicio de internet ofrecido por Proveedor A y la gran cantidad de contratos cancelados, la gerencia nacional de la empresa en cuestión decidió analizar los datos del proceso




que se seguía para atender a sus clientes y notaron que existía una mala predicción de los niveles de atención y satisfacción del cliente, así como también, de la demanda de llamadas, siendo muy inferiores a lo que realmente se esperaba y se recibía, lo que finalmente causó tener una cuantificación del personal que se requería. Por esta razón, una vez encontrado el problema, la gerencia nacional decidió buscar otro modelo de predicción que permita mejorar los indicadores actuales, primero mediante la predicción a próximos meses con lo cual se podrían tomar decisiones correctivas a corto plazo y planificar de mejor manera la atención del personal en la central telefónica.

### **3.2. Planteamiento de la serie de tiempo**

En base a lo descrito en la sección anterior, se plantea como objetivo diseñar un modelo adecuado para alcanzar un nivel o grado adecuado de servicio brindado por la central telefónica de Proveedor A, por ende, se tomó un registro histórico de las llamadas entrantes, y del nivel de servicio correspondiente a esos días, desde el 5 de enero del año 1 hasta el 26 de febrero del año 3 durante los 6 días de la semana. Se tienen registros de 112 semanas lo que da un total de 672 datos del nivel de servicio para la base histórica en la cual se asentará la serie de tiempo.

En la Figura 3.1 se observa como en el transcurso del tiempo el nivel de servicio iba disminuyendo como se indicó en el caso de estudio, esto se debe que a medida que aumentaban los clientes, el número de llamadas entrantes aumentaba y los empleados no abastecían para atender de manera óptima todas las llamadas.



**Figura 3.1. Grafica de serie de tiempo del total de llamadas por días.**  
**Fuente: Elaborada por el software Minitab**

Una observación adicional, es que el call center del área de soporte, de la empresa Proveedor A, en días normales recibe llamadas por casos de atención básica, logrando atender la mayoría de estas llamadas en un tiempo prudencial, sin embargo, en ocasiones se presentan problemas técnicos como alguna falla masiva, incrementando de manera crítica la cantidad de llamadas entrantes, teniendo como consecuencia el encolamiento de llamadas, o caso contrario, en días de fin de semana, el número de llamadas entrantes es mínimo logrando un nivel de atención óptimo.

Estos valores son lo que se pueden observar en la serie de tiempo, donde se visualizan en forma de picos altos o bajos, siendo estos valores atípicos considerados datos anormales que pueden afectar en gran medida la predicción que se realice, por lo que se recomienda eliminar estos valores mediante algún método de detección y eliminación de valores atípicos.


Existen distintos métodos para identificar estos valores, en este análisis se los identifico mediante un indicador, el cual se calcula con ayuda del valor promedio de los datos y la desviación estándar.

Debido a estos valores absurdos, y en busca de obtener el mejor modelamiento y mayor precisión en las pruebas de testeo y validación, se reemplazan los datos atípicos por un valor promedio del mismo día de semanas anteriores y se divide los datos en dos partes, la primera que facilita el pronóstico de los valores y la segunda parte que permite la validación de los mismos.

- **Primera parte:** Corresponde desde el 1ero de enero del año 1 al 12 de octubre del año 2, es decir, el 81.20% de los datos los cuales serán tomados como la información inicial de entrenamiento para la modelación de los métodos de predicción.
- **Segunda parte:** Corresponde desde el 13 de octubre del año 2 al 31 de marzo del año 3, es decir, el 18.80% de los datos los cuales serán utilizados para el testeo y validación de la selección del modelo que permita tener el menor nivel de error posible en el método de predicción a utilizar.

Las series de tiempo ayudan en la predicción de un modelo, si esta es estacionaria permite una predicción más exacta del modelo, ya que una serie estacionaria implica que la media y la varianza son constantes en el tiempo. No obstante, en la Figura 3.2 se observa que los valores de la serie no oscilan alrededor de una media constante, por lo tanto, la serie debe diferenciarse.

Los valores atípicos, solo fueron modificados en la primera parte, ya que los datos restantes serán utilizados para validación y testeo, estos deben mantenerse para validar con mayor exactitud los modelos desarrollados.



**Figura 3.2. Grafica de la primera parte de la serie de tiempo, sin valores atípicos.**

**Fuente: Elaborada por el software Minitab**

Una herramienta adicional que ofrece una idea del comportamiento de la varianza es el diagrama de cajas, el cual se presenta en la Figura 3.3 se observa que existe heterocedasticidad, es decir que la varianza a lo largo de las observaciones no es constante, aunque la diferencia entre estas no sea muy pronunciada.

Las graficas elaboradas, tienen como fin entender el comportamiento de los datos, permitiendo plantear el mejor método de pronóstico. Como ya se expuso en los objetivos, se emplearon métodos clásicos como el de descomposición de serie de tiempo y el de Winter para establecer una comparación con el método de redes neuronales.




Figura 3.3. Diagrama de Cajas por día de la semana.

Fuente: Elaborada por el software Minitab

### 3.3. Pronóstico por descomposición de serie de tiempo.

El método de descomposición de serie de tiempo, como lo indica su nombre, plantea la descomposición de la serie de tiempo en su tendencia, estacionalidad y ciclo, mediante una fórmula, proceso que se explica en el marco teórico. Para fines prácticos, en este estudio, se realiza la descomposición de la serie de tiempo utilizando el software Minitab. (Villavicencio, 2010)

El método de descomposición utilizado fue el multiplicativo, ya que es un método clásico para el análisis de este tipo de datos. Al realizar el análisis estacional, el software presenta las gráficas correspondientes, y la de descomposición de serie con pronóstico de los valores, en la cual se observa una tendencia de los valores, y los errores como el MAPE (Mean Absolute Percentage Error, Error Porcentual Absoluto Medio), el cual indica el valor porcentual por cada error realizado con respecto al valor real. (Villavicencio, 2010)

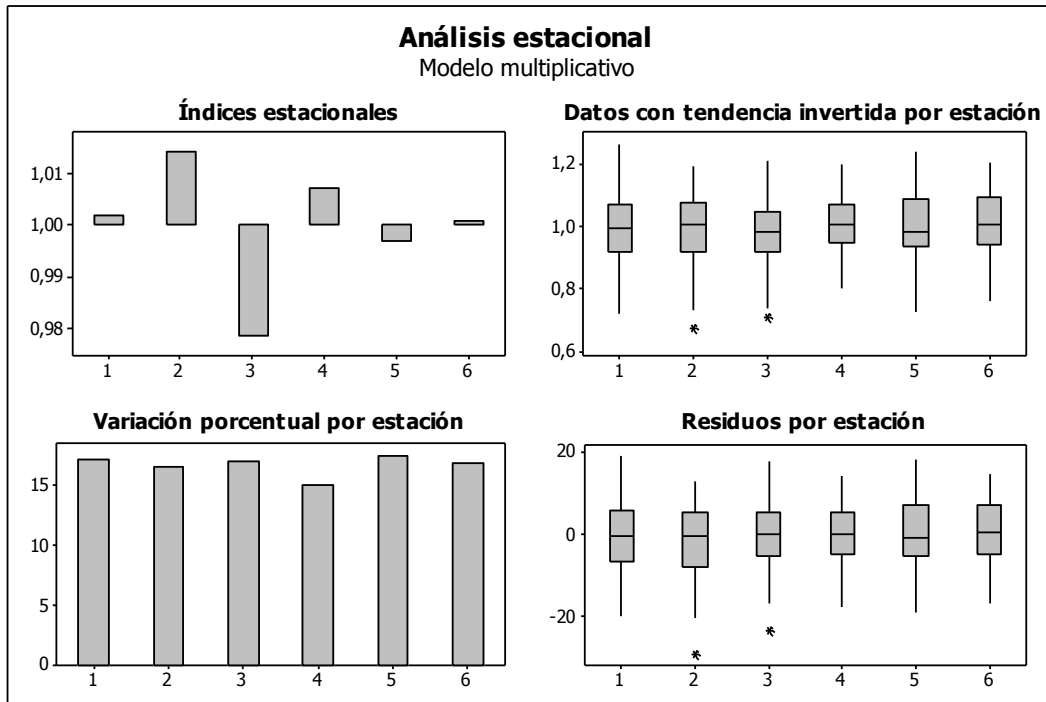


Figura 3.4. Análisis estacional de las llamadas entrantes según el día de la semana.

Fuente: Elaborada por el software Minitab

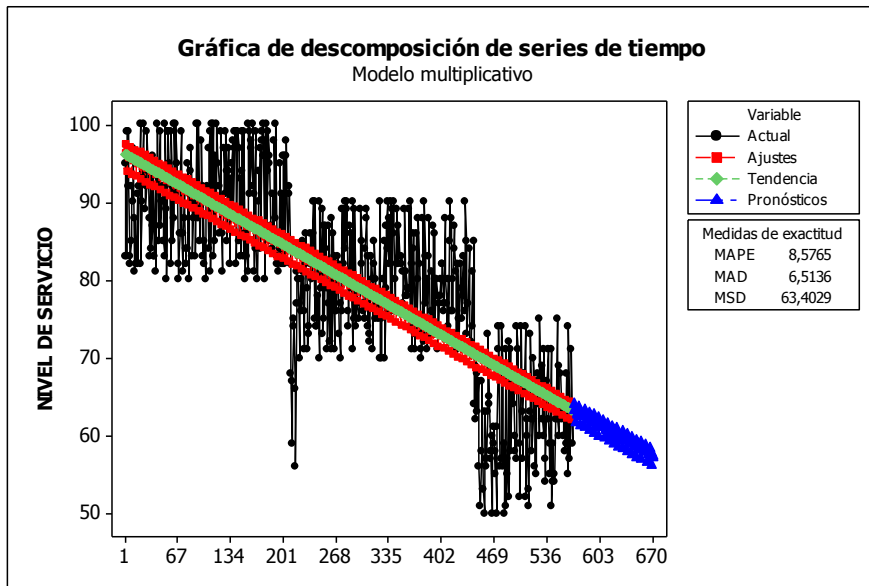


Figura 3.5. Grafica de descomposición de serie con pronóstico de valores.

Fuente: Elaborado por el software Minitab

Junto con todos los parámetros mencionados, el software elabora el cálculo de la ecuación de tendencia, y los índices estacionales de cada día de la semana, siendo los resultados los siguientes:

**Tabla 3.1. Índices estacionales de los días de la semana.**

$$Y(t) = 96.251 + 0.0579t$$

Periodo	Índice
1 (Lunes)	0,98198
2 (Martes)	0,99389
3 (Miércoles)	0,98094
4 (Jueves)	1,01309
5 (Viernes)	1,01085
6 (Sábado)	1,01926

Fuente: Autora

Se puede observar que al inicio de la semana las llamadas entrantes son en mayor cantidad, dificultando la atención óptima para todas, reflejando un índice menor a la unidad, lo que indica que los valores pronosticados se encuentran debajo de la tendencia estimada, a diferencia de los días jueves, viernes y sábado, donde la cantidad de llamas es la más baja de la semana, dando oportunidad a los operadores de atender las llamadas en su mayoría y se pronostica un nivel de servicio sobre el valor tendencial. A continuación, se presenta el pronóstico del nivel de servicio de las semanas consecuentes de la semana 95 hasta la semana 112, para así poder comprobar la efectividad del modelo, mediante la comparación y validez junto a los valores reales.




Figura 3.6. Grafica de validación de los datos.

Fuente: Elaborada por el software Minitab

En la figura 3.6 se puede observar como los valores pronosticados siguen la misma tendencia que los valores reales, a pesar del modelo no brindar valores cercanos, permite observar como el índice de nivel de servicio esta pronosticado a bajar en los próximos meses.

Para establecer la eficiencia del método se realiza el cálculo del error cuadrático medio (RMSE, Root-Mean-Square Error) y el error porcentual medio de los meses pronosticados obteniendo como resultado los valores mostrados en la tabla 3.2.

Tabla 3.2. Errores de pronóstico de los 4 meses por el método de descomposición de serie de tiempo.

	SERIES DE TIEMPO	
	RMSE	MAPE
MES 1	1585,96649	6,30485876%
MES 2	1715,19465	7,73152387%
MES 3	2060,36424	8,01283996%
MES 4	1441,2672	6,02820934%
PROMEDIOS	1700,69815	7,01935798

Fuente: Autora



Este pronóstico se realiza con el fin de poder actuar y mejorar el nivel de servicio antes de que se presente dicha situación, sin embargo, es recomendable el uso de metodologías adicionales para llegar a un mejor pronóstico.

### 3.4. Diseño de pronóstico por metodología de Winter

Al realizar el estudio de los datos obtenidos de los primeros meses, se determinó que la serie de tiempo tiene estacionalidad 6 y una componente tendencial, siendo factible el uso del método de Winter para la elaboración de pronóstico de los 4 meses consecuentes.

Para la elaboración del pronóstico mediante el método de Winter se hace uso de la herramienta de Solver y el software Minitab en conjunto; el software de Minitab permite encontrar los valores pronosticados para los 4 meses, sin embargo, se ingresa un valor fijo de las variables  $\alpha$ ,  $\beta$  y  $\gamma$ , mientras que Solver permite encontrar el valor de dichas variables que ofrezca el menor error, en conjunto se puede realizar un pronóstico minimizando el RMSE y el MAPE. Para encontrar los valores de  $\alpha$ ,  $\beta$  y  $\gamma$ , se coloca valores aleatorios al inicio, para poder encontrar el pronóstico de los valores iniciales que modelan el diseño.

J	A	B	C	D	E	F	G	H	I	J	K	L	M
1	Día	Periodo	Dt	At	Tt	St	Ft	error	ERROR CUAD			alpha	0,2655532
2	-5						1,054482759					beta	0,1258258
3	-4						0,903811252					gamma	0,1243863
4	-3						0,903811252					MAPE	6,4011264
5	-2						1,078039927					RMSE	34541,546
6	-1						1,078039927						
7	0			91,83333333	E	1,001814882							
8	1	1	95	96,25201395	5,8010292	1,028575602	103,2069	8,2068968	38,3255648				
9	2	2	83	99,3596056	5,4621252	0,895295555	92,236689	9,2366887	85,31641826				
10	3	3	83	101,3985967	5,0314065	0,893206143	94,73905	11,73906	137,8055237				
11	4	4	99	102,5830037	4,5473546	1,063986288	114,73579	15,73579	247,6151768				
12	5	5	99	103,0887779	4,0400778	1,065587753	115,4908	18,490804	271,9466036				
13	6	6	92	103,1050357	3,5325189	0,988181983	107,3353	15,3353	235,1100864				
14	7	1	82	95,54384656	3,6389472	1,000099056	109,68479	27,884787	766,447429				
15	8	2	88	95,68610559	2,3256735	0,887498771	91,484696	8,4846963	71,99007135				
16	9	3	85	100,2067093	2,0985481	0,887615793	91,117548	6,1175477	37,42439021				
17	10	4	92	98,13106511	1,5732278	1,048257577	108,8516	18,851597	283,9769104				
18	11	5	90	95,73284972	1,0736051	1,048054461	106,02443	16,02443	256,7825856				
19	12	6	97	97,18293829	1,11848	0,989452146	95,663362	1,3366375	1,78899981				
20	13	1	81	93,66087703	0,537079	0,985899306	88,583979	17,585979	309,2666513				
21	14	2	88	95,50441858	0,7014657	0,891718521	83,60057	4,8994298	19,35498258				
22	15	3	82	95,1982246	0,5746761	0,884548258	85,59367	3,5958698	11,51699483				
23	16	4	91	93,41089027	0,2774742	1,039044648	100,59467	9,5946688	88,25980254				
24	17	5	82	89,61693315	-0,2348145	1,03130499	98,190508	16,190508	262,1323577				
25	18	6	92	90,83056358	-0,1154782	0,999061988	88,489349	3,5606511	12,67823647				

Figura 3. 7 Muestra de la hoja de cálculo con los resultados del modelo de Winter.

Fuente: Autora

Las variables que se observan en la figura 3.7, se usan para elaboración del diseño mediante el método de Winter, y son el periodo, dato  $D_t$ , la serie

exponencial atenuada  $A_t$ , la estimación de la tendencia  $T_t$ , la estimación de la estacionalidad  $S_t$ , pronóstico  $F_t$ , y los respectivos errores.

$D_t$  Corresponde a los valores de nivel de servicio de los previos meses.

$A_t$ , es el valor de la serie exponencial atenuada, inicialmente se coloca el valor del promedio de los valores pertenecientes al primer periodo, el cual en este caso son los primeros 6 valores, este dato es usado como semilla para encontrar los siguientes, ingresando la siguiente fórmula en la celda correspondiente a  $A_t$ , del primer dato.

$$= \$M\$2*(C9/F3) + (1- \$M\$2)*(D8+E8)$$

$T_t$  se establece como semilla el valor de 6, debido a su componente tendencial cada 6 datos. Para encontrar el valor de estimación de tendencia se inserta la siguiente fórmula en la celda perteneciente a  $T_t$  del primer dato.

$$= \$M\$3*(D9-D8) + (1- \$M\$3)*E8$$

Para los valores de  $S_t$ , se calculan valores semillas de estimación tendencial que permita encontrar los valores de los primeros datos, ya que la fórmula hace uso de valores de  $S_t$  anteriores, estos 6 valores semilla se encuentran mediante la división entre los primeros datos y el valor semilla de  $A_t$ , es decir el promedio de esos valores. Los valores siguientes de  $S_t$  se encuentran ingresando la siguiente fórmula.

$$= \$M\$4*(C9/D9) + (1- \$M\$4)*F3$$

El pronóstico de los valores,  $F_t$ , se encuentra ingresando la siguiente fórmula.

$$= (D8+E8)*F3$$

Las fórmulas previamente presentadas, hacen referencia a las ecuaciones descritas en el marco teórico.

El error de pronóstico es la diferencia entre el valor de  $F_t$  y el dato  $A_t$ ; la herramienta de Solver permitirá encontrar los valores de  $\alpha$ ,  $\beta$  y  $\gamma$  que minimicen el error. Posterior a la elaboración del diseño y la optimización

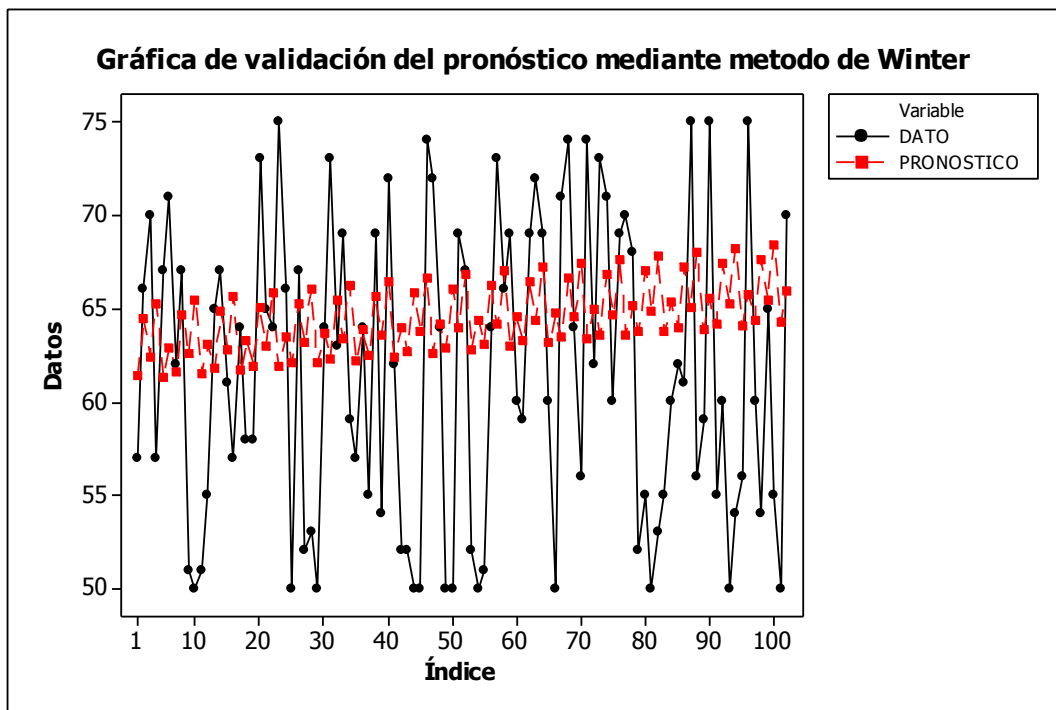
de los valores de MAPE y RMSE, se obtiene como resultado los siguientes valores de los parámetros mencionados.

**Tabla 3. 3. Valores de los parámetros del método de Winter**

$\alpha$	0,26355323
$\beta$	0,12582583
$\gamma$	0,12438627

Fuente: Autora

Una vez obtenido los parámetros del modelo de Winter, para un mejor pronóstico se procede a usar el software de Minitab ingresando los valores encontrados. Finalmente, en la figura 3.8 se puede observar la gráfica de los valores pronosticados juntos con los valores de la parte de validación y en la tabla 3.4 los valores de los errores de predicción.



**Figura 3. 8 Gráfica de los valores reales de la red y el pronóstico del método de Winter de validación.**

Fuente: Elaborada por el software Minitab

**Tabla 3. 4. Errores del pronóstico de 4 meses por el método de Winter**

	WINTER	
	RMSE	MAPE
MES 1	1785,06911	6,30880538%
MES 2	2039,11882	7,76986045%
MES 3	1145,72455	5,76421134%
MES 4	2569,82633	9,42592822%
PROMEDIOS	1884,9347	7,31720135

Fuente: Autora

### **3.5. Diseño de la RNA para pronóstico del nivel de servicio.**

Para el diseño de la red neuronal artificial, se debe encontrar el peso ideal de las neuronas, tanto entre las capas ocultas y las entradas, como el peso de la capa oculta con la salida, que ofrezca el mínimo valor de error de pronóstico.

La elección de estos pesos se realiza mediante un entrenamiento de la RNA, para lo cual se utilizará la hoja de cálculo Excel, que junto a su complemento Solver ejecuta un algoritmo mediante combinación de celdas, encontrando los valores de pesos que den como el mínimo valor posible de RMSE (Root-Mean-Square Error) o desviación de la raíz cuadrada media.

Una vez planteado el procedimiento para el diseño de la red neuronal, se definen las variables de entrada y salida para la RNA. Para este estudio las entradas están compuestas por los valores del grado de servicio de la semana 1 a la 95, estos datos serán utilizados para el entrenamiento de la red neuronal artificial mediante el Solver, y los datos de la semana 96 a la 102 son los valores que permite la validación del pronóstico de los siguientes 4 meses del índice de nivel de servicio.




Figura 3. 9. Proceso para elaborar pronósticos mediante una RNA.

Fuente: Autora

Con el objetivo de eliminar el ruido y acentuar la señal es necesario realizar un filtrado de los datos antes de ser utilizados en la red neuronal, incluso debido a que la función de activación empleada para determinar las salidas de la RNA será la tangente hiperbólica, se resalta la importancia del filtrado de los datos para no perjudicar la capacidad de aprendizaje de la red.

$$Norm = \frac{y_{t+5} - \frac{\sum_{i=1}^6 y_{t+i}}{6}}{S}$$

Donde  $y_t$  hace referencia a los datos de la serie temporal y S es la desviación estándar del grupo de 5 datos de la serie temporal implicados en el cálculo.

Mediante los datos normalizados se elabora el pronóstico de los valores del nivel de servicio de los cuatro meses consecuentes a los datos que fueron usados para el diseño de la red neuronal artificial. El número de entradas a

la red y el número neuronas en la capa oculta son parámetros que se establecen al realizar el experimento con distintas topologías y al realizar la comparación de los distintos RMSE.

La estacionalidad de la serie temporal es una base para plantear las distintas alternativas de topología para el diseño. Estas posibles topologías varían en el número de neuronas de la capa de entrada, de acuerdo con valores múltiplos de la estacionalidad  $s=6$ , siendo posible 12,18 y 24; adicional a esto son 4 los niveles de la capa oculta, permitiendo un total de 16 combinaciones posibles para las topologías de la RNA.

De acuerdo con lo recomendado por Masters<sup>1</sup> el número de neuronas en la capa oculta debe ser menor que en la capa de entrada y equivalente a  $(n*m)^{1/2}$ , donde  $n$  es el número de neuronas en la capa de entrada y  $m$  el número de salidas que tiene la red, y considerando que en la salida de la red hay una neurona, se ha determinado las siguientes 16 topologías (Masters, 1993).

De forma demostrativa se hará la definición de los parámetros de la RNA para la topología 8 planteada en la tabla 3.5, sin embargo, es importante recalcar que dicho procedimiento se debe realizar para los distintos tipos de topología involucrados en el experimento.

**Tabla 3. 5. Tipos de topología de RNA posibles.**

No. De Topología	No. De neuronas en la capa:		
	ENTRADA (M)	OCULTA (C)	SALIDA (N)
1	6	3	1
2	6	4	1
3	6	5	1
4	6	6	1
5	12	3	1
6	12	4	1
7	12	5	1
8	12	6	1
9	18	3	1
10	18	4	1
11	18	5	1
12	18	6	1
13	24	3	1
14	24	4	1
15	24	5	1
16	24	6	1

Fuente: Autora

Los parámetros para el diseño de la RNA con 12 entradas, 6 neuronas en la capa oculta y 1 salida son los siguientes:

- a) Número total de datos de entrada: 672
- b) Número total de datos después del filtrado: 666
- c) Numero de patrones de entrenamiento: 565
- d) Numero de patrones de testeo: 101
- e) Numero de neuronas en la capa de entrada: 12
- f) Numero de neuronas en la capa oculta: 6
- g) Numero de neuronas en la capa de salida: 1
- h) Matriz de pesos entre las capas de la red: 6x12 y 1x7
- i) La función tangencial hiperbólica de activación en cada neurona:

$$f_k(net_{jk}) = \tanh(net_{jk})$$

- j) La función lineal de la capa de salida es:

$$f_i(net_{ji}) = w_{10}x_0 + y_1w_{11} + y_2w_{21} + y_3w_{31} + y_4w_{41} + y_5w_{51} + y_6w_{61}$$

Una vez establecidos los parámetros de la RNA, se continúa con el proceso de aprendizaje, en el cual los pesos son modificados en busca de la combinación que minimice el RMSE, por lo tanto, una vez que los valores

de los pesos permanecen estables, se puede concluir que el aprendizaje ha terminado.

Para lograr el aprendizaje de la red neuronal se puede recurrir a distintos algoritmos, como Simulated Annealing o regla delta generalizada, sin embargo, el uso de la función tangente hiperbólica para las capas ocultas y función lineal para a capa de salida, facilitan el estudio permitiendo utilizar como herramienta el aplicativo de Microsoft Excel, como se planteó al inicio. Para la implementación de la red neuronal se han clasificado 16 hojas de cálculo, una para que cada topología de la RNA, y se utiliza la función de Solver que mediante algoritmo encuentra la combinación de las celdas que contiene los pesos, tales que ofrezcan el mínimo error cuadrático medio.

A continuación, se muestra la figura 3.10, que contiene una porción de la serie temporal y el resultado de las operaciones realizadas para la obtención del pronóstico mediante una red neuronal artificial, basados en la topología #8 (12 entradas, 6 capas ocultas, 1 salida).



ALFA	NORM	INI 1	INI 2	INI 3	INI 4	INI 5	INI 6	OUI	OUI1	OUI2	OUI3	OUI4	OUI5	OUI6	OR	DIF	DIF CUAD	POSP
95		14,00329	37,40049222	10,03093	2,274704848	1,661267	31,450662											
83		0	4,602861941	77,32606	24,12184643	16,80324	5,61189426											
83		72,98559	17,56274358	18,6483	21,49671203	24,01476	0,18085484											
99		44,35251	70,58535991	10,06853	7,958692638	18,2733	4,26743436											
99		0,309024	34,80086521	15,25046	0,46725712	20,32827	34,9963018											
92		13,50709	9,749575046	17,22436	15,8430036	0	49,9280938											
82		0,874243815	9,14496	0	0,212954	15,92926204	33,10141	36,3333443										
83		0,291212003	6,313972	23,31497856	64,14791	9,929242339	11,55021	2,96233527										
85		-0,926520543	17,16599	6,401468992	18,31923	22,57975112	39,28473	47,3039175										
92		-0,845770931	0	5,093682181	65,02251	0	34,30659	66,37713818										
90		-0,533127781	83,62485	70,15732029	1,6921	14,27573846	18,84568	5,03456367										
97		0,958589368	0,164099	24,77301222	8,66377	86,4527998	88,52799	1,33368857										
81		0,417313832	0	0,02477	0	0	0	0										
88		1,608682512																
82		-1,262455977																
91		-0,056915648																
82		-0,948157075	6,807923	-104,7622045	7,66935	-15,91797146	-41,01071	-28,39653363	0,999997558	-1	1	1	-1	-1	0,02477	-0,605531	0,366668	86,99109947
92		0,63031063	-166,9787	-72,90847549	94,18931	32,38125991	-23,4152	7,03819719	-1	-1	-1	-1	-1	0,999998	0,02477	0,925982	0,857443	86,12235571
92		-0,901211818	-17,03964	-21,16254209	-218,1176	-94,16238157	-89,64787	46,9852636	-1	-1	-1	-1	-1	-1	-0,02477	-0,89358	0,798486	87,71566407
100		0,868810059	-90,91043	4,078635371	-15,21296	19,50827291	-0,69465	12,6040598	-1	0,999427	-1	-1	-1	-1	-0,02477	-0,432777	0,187296	89,66285635
82		0,408006938	137,1072	104,2797283	-137,7244	41,48428692	86,48605	-64,319713	-1	-1	-1	-1	-1	-1	-0,02477	-1,616424	2,612825	89,66285635
90		1,591653407	107,4019	142,2687006	167,2155	156,4361546	147,8677	-64,8489553	1	1	1	1	1	-1	0,02477	1,024581	1,049767	89,83660293
93		-0,999811018	209,9421	39,21567013	20,77354	-21,2789943	23,07808	73,1603823	1	1	1	1	-1	1	0,02477	0,258462	0,066802	91,64336784
100		-0,233691357	-160,0006	-74,98662729	263,6518	-9,289285125	-11,6018	109,385345	-1	-1	-1	-1	-1	1	0,02477	-0,001008	1,02506	93,00090631
93		0,025778676	-17,35277	-1,570076594	-107,6691	3,176058951	35,15628	57,0770846	-1	-0,917038	-1	-1	-1	1	-0,02477	-0,951943	0,906195	92,83273243
96		0,92717265	-48,54231	11,76309441	49,57441	73,99131807	34,59581	-67,5829451	-1	-1	1	1	1	-1	0,02477	-0,077733	0,006042	92,48414019
89		0,102503468	92,79713	18,08981822	-114,8754	22,49443558	59,6926	90,2726674	1	1	1	-1	-1	1	-0,02477	-0,685878	0,470428	93,39999467
92		-0,661107357	-20,39012	65,6623293	116,2636	66,565358907	69,02843	98,1470918	-1	-1	-1	-1	-1	-1	0,02477	1,207508	1,458076	93,97656494

Figura 3.10. Resultados de la topología 12x6x1 de RNA en Solver.

Fuente: Autora

En la figura 3.10, se observan el contenido de las entradas, salidas y operaciones respectivas para el diseño de la red neuronal.

La primera fila “ALFA”, hace referencia a los valores de niveles de servicio que corresponden a la primera parte de la serie temporal. Es importante indicar que, para realizar el pronóstico, los cálculos son el mismo que se realizan para los valores de entrada, sin embargo, el aprendizaje de los pesos debe realizarse sin incluir dichos valores.

En la segunda fila “NORM” se presentan los datos filtrados, como ya se mencionó previamente esto se realiza con el fin de atenuar el ruido y obtener un mejor aprendizaje de la RNA.

Las filas de IN1 a IN6 contienen los pesos de los 12 nodos de la capa de entrada con el primer nodo de la capa oculta, y el peso de conexión entre la capa oculta y la capa de salida, después del entrenamiento mediante la herramienta de Solver, siendo los resultados para la topología 8, los siguientes pesos.

**Tabla 3. 6. Pesos de la RNA culminado el entrenamiento.**

No. Neuronas en la capa de Entrada	No. Neuronas en la capa Oculta					
	1	2	3	4	5	6
1	14,00329	37,4004922	10,0309335	2,27470485	1,66126729	31,450662
2	0	4,60286194	77,3260573	24,1218464	16,8032441	5,61189426
3	72,985589	17,5627436	18,6482953	21,496712	24,0147602	0,18085484
4	44,3525059	70,5853599	10,0685334	7,95869264	18,2732958	4,26743436
5	0,30902443	34,8008652	15,2504642	0,46725712	20,3282726	34,9963018
6	13,5070884	9,74957505	17,224355	15,8430036	0	49,9280938
7	9,14496018	0	0,21295392	15,929262	33,1014066	36,3333443
8	6,31397206	23,3149786	64,1479136	9,92924234	11,5502065	2,95233527
9	17,1659936	6,40146899	18,3192277	22,5797511	39,2847259	47,3039175
10	0	5,09368218	65,0225132	0	34,3065873	66,3713818
11	83,6248498	70,1573203	1,69209953	14,2757385	18,8456753	5,03456367
12	0,16409927	24,7730122	8,66377002	86,45928	88,5279854	1,33368857
1	0	0	0,02477019	0	0	0
No. Neuronas en la capa de Salida	No. Neuronas en la capa Oculta					
	1	2	3	4	5	6

**Fuente: Autora**

Para el entrenamiento de los pesos mostrados en la tabla 3.6, primero se asignan pesos aleatorios, y se calcula el valor de entrada total, valores que se observan en la figura 3.10, correspondientes a los valores de IN1 a IN6

de la fila 18 en adelante. El input total es la suma ponderada de los valores de la serie. Para la obtención de dichos valores se ingresa las siguientes formulas en las filas 18 correspondiente a cada entrada, y se arrastra hasta la fila 571 donde culminan los valores de la primera parte de la serie temporal.

- **IN1**  

$$= \$C\$2 * \$B7 + \$C\$3 * \$B8 + \$C\$4 * \$B9 + \$C\$5 * \$B10 + \$C\$6 * \$B11 + \$C\$7 * \$B12 + \$C\$8 * \$B13 + \$C\$9 * \$B14 + \$C\$10 * \$B15 + \$C\$11 * \$B16 + \$C\$12 * \$B17 + \$C\$13 * B18$$
- **IN2**  

$$= \$D\$2 * \$B7 + \$D\$3 * \$B8 + \$D\$4 * \$B9 + \$D\$5 * \$B10 + \$D\$6 * \$B11 + \$D\$7 * \$B12 + \$D\$8 * \$B13 + \$D\$9 * \$B14 + \$D\$10 * \$B15 + \$D\$11 * \$B16 + \$D\$12 * \$B17 + \$D\$13 * B18$$
- **IN3**  

$$= \$E\$2 * \$B7 + \$E\$3 * \$B8 + \$E\$4 * \$B9 + \$E\$5 * \$B10 + \$E\$6 * \$B11 + \$E\$7 * \$B12 + \$E\$8 * \$B13 + \$E\$9 * \$B14 + \$E\$10 * \$B15 + \$E\$11 * \$B16 + \$E\$12 * \$B17 + \$E\$13 * \$B18$$
- **IN4**  

$$= \$F\$2 * \$B7 + \$F\$3 * \$B8 + \$F\$4 * \$B9 + \$F\$5 * \$B10 + \$F\$6 * \$B11 + \$F\$7 * \$B12 + \$F\$8 * \$B13 + \$F\$9 * \$B14 + \$F\$10 * \$B15 + \$F\$11 * \$B16 + \$F\$12 * \$B17 + \$F\$13 * \$B18$$
- **IN5**  

$$= \$G\$2 * \$B7 + \$G\$3 * \$B8 + \$G\$4 * \$B9 + \$G\$5 * \$B10 + \$G\$6 * \$B11 + \$G\$7 * \$B12 + \$G\$8 * \$B13 + \$G\$9 * \$B14 + \$G\$10 * \$B15 + \$G\$11 * \$B16 + \$G\$12 * \$B17 + \$G\$13 * \$B18$$
- **IN6**  

$$= \$H\$2 * \$B7 + \$H\$3 * \$B8 + \$H\$4 * \$B9 + \$H\$5 * \$B10 + \$H\$6 * \$B11 + \$H\$7 * \$B12 + \$H\$8 * \$B13 + \$H\$9 * \$B14 + \$H\$10 * \$B15 + \$H\$11 * \$B16 + \$H\$12 * \$B17 + \$H\$13 * \$B18$$

Posterior al cálculo de las entradas, se encuentra las salidas las que se muestran en las columnas de OU1 a OU6, dichos valores se obtienen aplicando la función de activación tangente hiperbólica a cada valor de input total de IN1 a IN6. Esta operación es más sencilla gracias a Excel, el cual

ofrece la función de la tangente hiperbólica en la sección funciones de Matemáticas y Trigonométricas. De la misma forma que en los cálculos anteriores se ingresa la siguiente fórmula y se arrastra hasta la celda 512.

$$\begin{aligned}
 \mathbf{OU1} &= \mathbf{TANH (C18)} & \mathbf{OU2} &= \mathbf{TANH (D18)} & \mathbf{OU3} &= \mathbf{TANH (E18)} \\
 \mathbf{OU4} &= \mathbf{TANH (G18)} & \mathbf{OU5} &= \mathbf{TANH (H18)} & \mathbf{OU6} &= \mathbf{TANH (I18)}
 \end{aligned}$$

La fila OR es la salida de red neuronal, este valor corresponde a la salida de la RNA debido a la función de activación lineal de la neurona de la capa de salida, por lo que se encuentra mediante la suma ponderada de los valores de las celdas correspondientes de OU1 a OU6 y los pesos de la tabla 3.6, ingresando la siguiente fórmula y arrastrándola hasta la celda de la fila 512.

$$\mathbf{OR} = \mathbf{\$C\$14 * \$I18 + \$D\$14 * \$J18 + \$E\$14 * \$K18 + \$F\$14 * \$L18 + \$G\$14 * \$M18 + \$H\$14 * \$N18}$$

Una vez obtenida las entradas y la salida de la RNA se encuentra el error y el error medio cuadrático, valores que sirve para el entrenamiento de los pesos ya que el objetivo es minimizar el RMSE.

La celda “DIF” presenta el error entre la salida y el valor de la entrada mediante la diferencia de estos a través de la función  $\mathbf{DIF} = \mathbf{\$O18 - \$B19}$ , ya que la salida corresponde al valor pronosticado previo a la desnormalización, consiguiente a eso se encuentra el valor del error medio cuadrático, elevando al cuadrado los valores de la celda DIF.

Finalmente, el campo “POSP” contiene los valores de predicción “des-normalizados”, con los cuales se evaluaron los errores de pronóstico. Para obtener el valor “des-normalizado” de la RNA se debe ingresar la siguiente fórmula:

$$\mathbf{POSP} = \mathbf{O18 * DESVESTA (\$A13:\$A18) + PROMEDIO (\$A13:\$A18)}$$

Es importante volver a mencionar que dichas operaciones son realizadas inicialmente con los valores de pesos asignados de forma aleatoria, para obtener los valores de errores iniciales e ingresar la celda que contenga el valor de la suma de los RMSE en las opciones de Solver, como celda

objetivo, y las celdas de los pesos se ingresan en la sección de “Combinando las celdas”, ya que la función de Solver es encontrar la combinación de esos valores que dé como resultado el mínimo valor de la celda objetivo.

Para seleccionar la RNA que ofrezca el mejor pronóstico de los niveles de servicio de los meses consecuentes, se elabora una tabla que muestre los valores obtenidos de RMSE de las distintas topologías, valores que se observan en la tabla número 3.7, facilitando la comparación de los RMSE con el fin de escoger la topología que presente el menor error de pronóstico.

**Tabla 3. 7. Resultado de los RMSE de las distintas topologías.**

NE	NO	SALIDA	RMSE
6	3	1	468,6355
6	4	1	484,8523
6	5	1	503,6132
6	6	1	527,8826
12	3	1	457,8635
12	4	1	467,5017
12	5	1	500,0478
12	6	1	496,8836
18	3	1	452,0103
18	4	1	455,9752
18	5	1	517,5048
18	6	1	462,1841
24	3	1	605,7517
24	4	1	449,0021
24	5	1	454,2577
24	6	1	460,762

**Fuente: Autora**

Al analizar la varianza del diseño factorial de 4x4, es decir de las 16 topologías posibles, se observa un coeficiente de varianza de 8,38% el cual no muestra interacción en los resultados obtenidos de RMSE. Sin embargo, haciendo un análisis más profundo, se contempla que la topología con 24 neuronas en la capa de entrada y 4 neuronas la capa oculta, tiene un mejor comportamiento, siendo estadísticamente mejor que las demás al presentar el menor error de pronóstico.




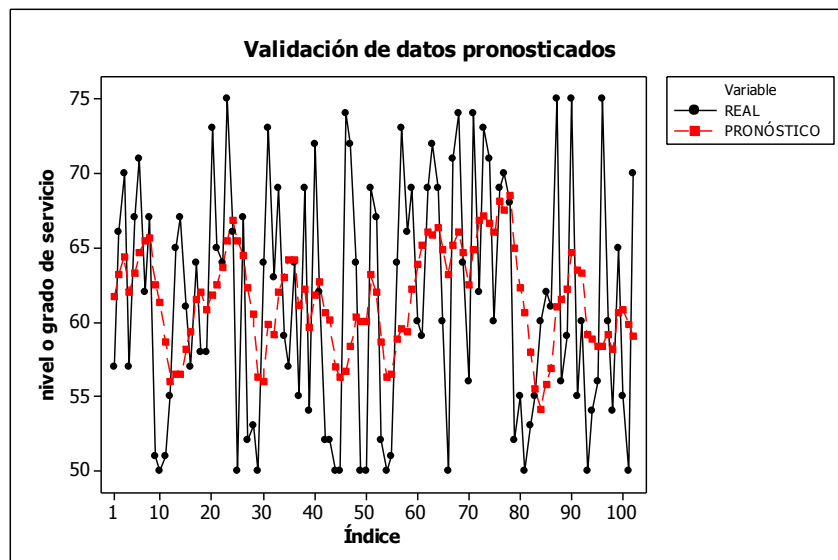
Figura 3. 11. Grafica de los valores reales y proyectados de la primera parte de la serie de tiempo, correspondientes a la etapa de entrenamiento.

Fuente: Elaborada por el software Minitab

Tabla 3. 8. Errores del pronóstico de 4 meses por el método de una red neuronal artificial.

	RNA	
	RMSE	MAPE
MES 1	1458,80685	5,83415335%
MES 2	1733,33795	7,48376489%
MES 3	1059,58404	5,63690127%
MES 4	1515,19133	6,74151177%
PROMEDIOS	1441,73004	6,42408282

Fuente: Autora



**Figura 3. 12. Grafica de los valores reales y proyectados de los meses consecuentes, correspondiente a la parte de validación de datos.**

**Fuente: Elaborado por el software Minitab.**

Al igual que en los métodos utilizados previamente, se logra observar como los valores pronosticados no reflejan el valor real exactamente, por lo que se obtiene el valor de RMSE mencionado en la tabla 3.8, sin embargo, la estimación por red neuronal artificial presenta mayor exactitud que los pronósticos realizados con los otros métodos.

Se puede observar en la figura 3.12, que diferente al resultado obtenido de los métodos de diseño previos, la red neuronal intenta seguir las tendencias de corto plazo en base a datos de las semanas anteriores, logrando mejorar la tendencia de los valores pronosticados.

### **3.6. Comparación de resultados y selección del mejor método**

En la sección anterior se elaboró el pronóstico de los 4 meses posteriores de la primera parte de los datos mediante la implementación de 3 métodos distintos: modelo de descomposición de la serie de tiempo, modelo de ajuste exponencial de Winter, y modelo mediante el diseño de una red neuronal artificial, obteniendo resultados aceptables, con distintos valores de RMSE que permite validar la exactitud de dichos pronósticos y así poder

analizar y definir cuál es el mejor modelo de pronóstico para el presente proyecto.

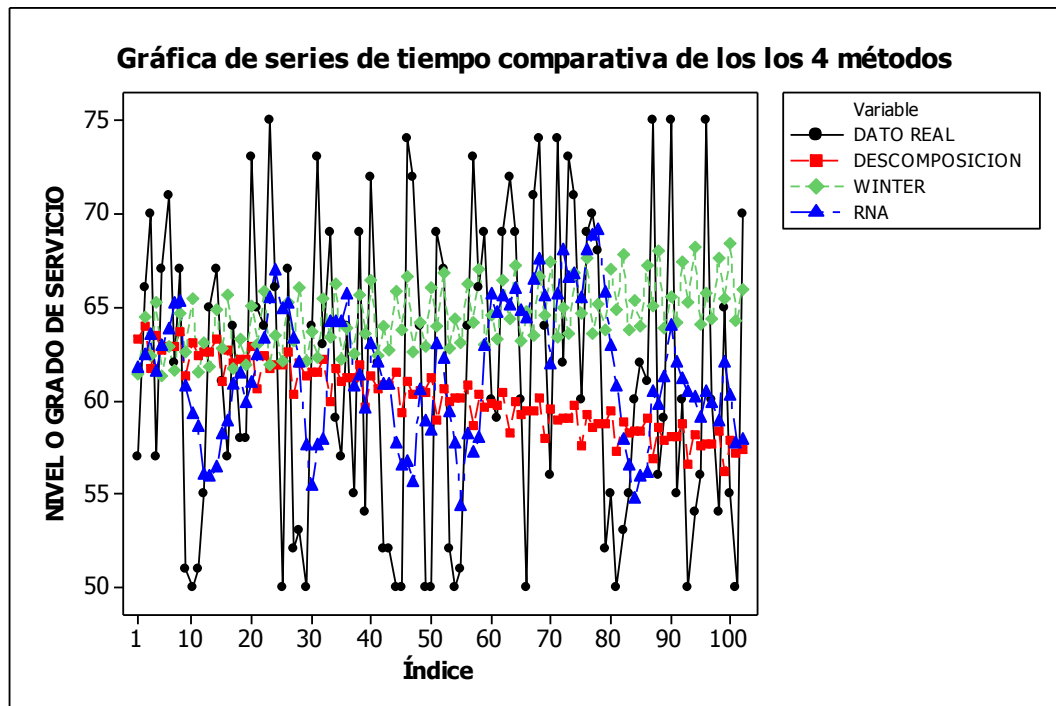


Figura 3.13. Gráfica comparativa de las predicciones obtenidas por los distintos métodos y los valores reales de la etapa de validación.

Fuente: Elaborada por el software Minitab.

En este capítulo se analizaron los resultados obtenidos mediante los distintos métodos, comparando los valores de errores de ajuste y pronóstico de cada diseño, para la selección del mejor modelo que le permita a la empresa ProveedorA obtener una mejor predicción de sus valores de nivel o grado de servicio, logrando resolver con anticipación el problema de disminución en su grado de servicio de atención al cliente.

Para la elaboración de cada método, se realiza el diseño basados en los datos de la etapa de entrenamiento, elaborando un pronóstico con un valor de RMSE que en cada diseño se busca ser minimizado. En la tabla 3.9 se podrá observar los valores de RMSE y MAPE obtenidos en la etapa de entrenamiento de cada método.



**Tabla 3.9. Cálculo de RMSE y MAPE de los distintos modelos en la etapa de entrenamiento.**

METODO	RMSE	MAPE	COEF COORR
<b>DESCOMPOSICION</b>	747,7853	8,5765%	0,994
<b>WINTER</b>	31509,6349	6,4011%	0,814
<b>RNA</b>	449,0021	4,8572%	0,881

**Fuente: Autora**

En la tabla se puede observar como el diseño mediante una red neuronal artificial logra el menor valor de RMSE, el modelo de 24x4x1 dio como resultado en la etapa de entrenamiento un error cuadrático medio de 449,0021, seguido por el método de descomposición de serie de tiempo, de igual manera se contempla el valor de error cuadrático medio del método de Winter elevado, esto se debe a que el modelo de Winter presenta mejores resultados ante un pronóstico de corto plazo.

Con respecto al coeficiente de correlación, los valores más óptimos son los del método de descomposición de serie y RNA, sin embargo, junto con la comparación del RMSE se puede concluir que el pronóstico mediante redes neuronales artificiales es el método que mejor se ajusta al estudiar el comportamiento de las series temporales.

Los valores anteriores son obtenidos en la etapa de entrenamiento, es decir durante el diseño y elección de parámetros que minimicen estos valores para proceder con el pronóstico de los 4 meses consiguientes.

Una vez realizado el pronóstico de los siguientes meses se procede con la etapa de validación, donde se calcula el error de pronóstico de cada más, para poder efectuar una mejor comparación entre los distintos métodos. Los valores de RMSE, MAPE y coeficiente de correlación de cada mes según el método utilizado se presentan en la tabla 3.10.

**Tabla 3.10. Cálculo RMSE, MAPE y de coeficiente de correlación de los distintos modelos de pronóstico en la etapa de validación.**

Elaborada por la autora

	SERIES DE TIEMPO			WINTER			RNA		
	RMSE	MAPE	COEF CORR	RMSE	MAPE	COEF CORR	RMSE	MAPE	COEF CORR
MES 1	1585,96649	6,3048587%	0,217	1785,06911	6,30880538%	0,033	1458,80685	5,83415335%	0,308
MES 2	1715,19465	7,7315238%	0,157	2039,11882	7,76986045%	0,193	1733,33795	7,48376489%	0,175
MES 3	2060,36424	8,01283996%	0,126	1145,72455	5,76421134%	0,091	1059,58404	5,63690127%	0,356
MES 4	1441,2672	6,02820934%	0,196	2569,82633	9,42592822%	0,056	1515,19133	6,74151177%	0,261
Promedios	1700,69815	7,01935798		1884,9347	7,31720135		1441,73004	6,42408282	

En el análisis comparativo de la etapa de validación se observa nuevamente que el valor de RMSE de los meses correspondientes al modelo de RNA es menores a los métodos de Winter y de descomposición, de igual forma con el valor del error medio.

El coeficiente de correlación permite tener una idea de la relación que guardan los valores pronosticados con los valores reales, notando como este coeficiente se va deteriorando, especialmente en el método de Winter, debido a que este modelo es comúnmente usado para pronósticos de corto plazo.

La figura 3.13, junto con la tabla 3.10 refuerza la elección del diseño de una red neuronal artificial como el mejor modelo para la solución de pronósticos de nivel o grado de servicio del ProveedorA.

La elección del modelo se basa principalmente en buscar el menor error en los promedios de todos los indicadores en estudio y en la facilidad de desarrollo, el modelo de una RNA presenta los mejores resultados en la etapa de validación.

## CONCLUSIONES

Mediante el uso de una red neuronal artificial se realizó el pronóstico de los valores del nivel o grado de servicio de los siguientes cuatro meses en base a valores previos. Los resultados obtenidos permitieron concluir sobre la efectividad de la metodología de las redes neuronales, siendo esta la metodología más efectiva al realizar pronósticos, debido a que en la validación de datos los valores de RMSE y MAPE obtenidos fueron los mínimos en comparación a las demás metodologías.

Al realizar el diseño de la red neuronal artificial, se planteó 16 topologías posibles variando el número de entradas y capas ocultas en base a la estacionalidad de los datos, en cada topología se realizó el proceso de encontrar los valores de salida variando el número de entradas y calculando el error cuadrático medio con el objetivo de encontrar la que ofrezca los pronósticos más acertados, conclusión que se obtiene a través de la comparación de los valores de RMSE. Observando los valores de errores se pudo concluir que la topología que más se adaptaba al caso de estudio es la que plantea 24 entradas y 4 capas ocultas.

Durante el análisis del caso de estudio se planteó distintos métodos de predicción, como descomposición de serie de tiempo, método de Winter y redes neuronales con el objetivo de identificar el método que brinde las predicciones más acertadas.

Una vez elaborada las predicciones a través de los distintos métodos, se pudo concluir que el método de descomposición de serie es el más sencillo en su elaboración, sin embargo, sus predicciones brindan más una tendencia que una exactitud en los datos. El método de Winter brinda resultados más exactos cuando es usado para predicciones a corto plazo, a medida que la predicción se extiende el error aumenta. Finalmente el diseño de una red neuronal artificial tiene un procedimiento más extenso, plantea una normalización de los datos para resaltar el comportamiento de la señal atenuando el ruido, y establece la salida mediante una función hiperbólica, ofreciendo a diferencia de los otros métodos una precisión mayor en la predicción de datos.

Adicional a las conclusiones obtenidas respecto a las metodologías empleadas para la predicción de datos, se pudo observar que el nivel o grado de servicio del Proveedor A tiene una tendencia a disminuir los primeros días de la semana, y conforme pasan los meses disminuye de manera preocupante.

## **RECOMENDACIONES**

En el caso de estudio se menciona como el Proveedor A, el cual brinda servicio de Telecomunicaciones fue creciendo, aumentando su cobertura y número de clientes, con la tendencia que presentan los valores de nivel o grado de servicio a disminuir, se puede concluir que el personal de call center no logra abastecer todas las llamadas que entran a la central, por lo que se recomienda el incremento de personal o tácticas adicionales de atención al cliente que permitan mejorar el nivel o grado de servicio de la empresa.

Se recomienda el uso de redes neuronales artificiales para la predicción de valores, no solo para el nivel o grado de servicio sino para todos los parámetros en general del nivel de atención al cliente. Siendo compleja la predicción de datos mediante RNA, se puede hacer uso de softwares que elaboran predicciones mediante algoritmos que sigan dicha metodología. La importancia de un buen sistema de predicción radica en la prevención y corrección de parámetros que tiendan a disminuir, afectando el rendimiento de la empresa.

## BIBLIOGRAFÍA

Haugeland, J. (1996). Artificial intelligence (1st ed., pp. 9-13). Cambridge, Mass. [u.a.]: MIT-Press.ç

Flórez López, R., & Fernández Fernández, J. (2008). Las Redes neuronales artificiales (pp. 11-15). Oleiros: Netbiblo.

Fernando, I., & Carlos, S. (2014). Redes Neuronales Artificiales. Concepción, Chile: Departamento de Física, Universidad de Concepción.

Flórez López, R., & Fernández Fernández, J. (2008). Las redes neuronales artificiales (pp. 21-29). Oleiros, La Coruña: Netbiblo.

Lafon, S. (2002). REDES NEURONALES (1st ed., pp. 1-5). Montevideo: Santiago Lafon. Recuperado a partir de <http://iie.fing.edu.uy/ense/assign/tes/materiales/monografias/RedesNeuronales.pdf>

Hilera González, J., & Martínez Hernando, V. (2000). Redes neuronales artificiales. México: Alfaomega.

De Moya Anegón, F., Herrero Solana, V., & Guerrero Bote, V. (1998). La aplicación de Redes Neuronales Artificiales (RNA): a la recuperación de la información. *Revistes Catalanes Amb Accés Obert*, 147-152.

Haykin Symon. (1999) Neural Network. A Comprehensive Foundation (2a ed): Prentice-Hall.

Fuente Aparicio, M., Gonzalez Palenzuela, E., Zamarreño Cosme, J., & Calonge Cano, T. (1999). Aplicaciones de las redes de neuronas en supervisión, diagnosis y control de procesos (1st ed.). Caracas (Venezuela): Equinoccio.

Pino Díez, R., Gómez Gómez, A., & Abajo Martínez, N. (2001). Introducción a la inteligencia artificial. Gijón: Servicio de Publicaciones. Universidad de Oviedo.

Haykin Symon. (1999) Neural Network. A Comprehensive Foundation (2a ed): Prentice-Hall.

Anthony, M., & Bartlett, P. (1999). Neural network learning (1st ed.). Cambridge (Inglaterra): Cambridge University Press.

Martín del Brío, B., & Sanz Molina, A. (2001). Redes neuronales y sistemas borrosos (1st ed.). Madrid: RA-MA.

Hanke, E. y Reitsch, G. (1996) Pronósticos en los Negocios (5a ed) Prentice-Hall.

Ludlow Wiechers, J. (1999). Econometría, modelos y pronósticos (2nd ed.). [Azcapotzalco, México]: Universidad Autónoma Metropolitana-Azcapotzalco.

Peña, D. (2010) Análisis de Series Temporales: Alianza Editorial.

Wedding II y Cios (1996). Time series forecasting by combining RBF network, certainty factor, and the Box-Jenkins model. Neurocomputing, 10, (pp. 149-168).

Faraway, J. y Chatfield, C. (1998). Time series forecasting with neural networks: a comparative study using the airline data. Applied Statistic, 47 (2), pp. 231-250.

Gould, F.J, Eppen G.D, Schmidt C. P. (1992) Investigación de Operaciones en la Ciencia Administrativa México: Hall Hispanoamérica S.A.



## DECLARACIÓN Y AUTORIZACIÓN

Yo, **Paredes Ponce María Cecilia**, con C.C: # **1310375785** autor/a del trabajo de titulación: **Aplicación de redes neuronales artificiales en la estimación del nivel de servicio en un CALLCENTER** previo a la obtención del título de **Magíster en Telecomunicaciones** en la Universidad Católica de Santiago de Guayaquil.

1.- Declaro tener pleno conocimiento de la obligación que tienen las instituciones de educación superior, de conformidad con el Artículo 144 de la Ley Orgánica de Educación Superior, de entregar a la SENESCYT en formato digital una copia del referido trabajo de titulación para que sea integrado al Sistema Nacional de Información de la Educación Superior del Ecuador para su difusión pública respetando los derechos de autor.

2.- Autorizo a la SENESCYT a tener una copia del referido trabajo de titulación, con el propósito de generar un repositorio que democratice la información, respetando las políticas de propiedad intelectual vigentes.

Guayaquil, 24 de octubre de 2018

f. \_\_\_\_\_

Nombre: **Paredes Ponce Maria Cecilia**

C.C: **1310375785**





**Presidencia  
de la República  
del Ecuador**



**Plan Nacional  
de Ciencia, Tecnología,  
Innovación y Saberes**



**SENESCYT**  
Secretaría Nacional de Educación Superior,  
Ciencia, Tecnología e Innovación

<b>REPOSITORIO NACIONAL EN CIENCIA Y TECNOLOGÍA</b>			
<b>FICHA DE REGISTRO DE TESIS/TRABAJO DE TITULACIÓN</b>			
<b>TÍTULO Y SUBTÍTULO:</b>	Aplicación de redes neuronales artificiales en la estimación del nivel de servicio en un CALLCENTER.		
<b>AUTOR(ES)</b>	Paredes Ponce María Cecilia		
<b>REVISOR(ES)/TUTOR</b>	MSc. Orlando Philco Asqui; MSc. Luis Córdova Rivadeneira / MSc. Manuel de Jesús Romero Paz		
<b>INSTITUCIÓN:</b>	Universidad Católica de Santiago de Guayaquil		
<b>FACULTAD:</b>	Sistema de Posgrado		
<b>PROGRAMA:</b>	Maestría en Telecomunicaciones		
<b>TÍTULO OBTENIDO:</b>	Magister en Telecomunicaciones		
<b>FECHA DE PUBLICACIÓN:</b>	24 de octubre del 2018	<b>No. DE PÁGINAS:</b>	<b>79</b>
<b>ÁREAS TEMÁTICAS:</b>	Redes neuronales artificiales, Metodología de predicción, Modelos de pronóstico, Series de Tiempo, Método de Winter, ARIMA		
<b>PALABRAS CLAVES/ KEYWORDS:</b>	MINITAB, SOLVER, RNA, pronóstico, Call center		
<b>RESUMEN/ABSTRACT:</b>	<p>En el presente proyecto se realiza la construcción de una red neuronal artificial para pronosticar el grado o nivel servicio de un centro de llamadas o call center perteneciente a un proveedor de internet. Esta red se elabora con la finalidad de demostrar que a través de este tipo de modelo computacional se puede predecir el grado de calidad en el servicio de un call center, es decir, poder determinar la eficiencia de atención de los operadores en los futuros días en función a una base de datos del nivel de servicio en días previos. Se empieza por dar una descripción concisa de los modelos tradicionales de determinación o pronóstico de una variable, así como también, se detallan la composición y funcionamiento de las redes neuronales artificiales, tanto en sus topologías, algoritmos de aprendizaje, aplicativos en diferentes áreas y su utilidad en la actualidad. Posterior a esto se define el problema a resolver especificando el método a utilizar, los modelos de predicción, métodos de ajuste exponencial y diferentes topologías de redes neuronales artificiales para poder llegar a la solución deseada. Con estos aditamentos se implementa una red neuronal utilizando como interfaz MINITAB y como elemento de aprendizaje SOLVER, con la finalidad de ver en base a análisis comparativos los errores de estimación y las etapas de entrenamiento de los modelos asociados para este estudio.</p>		
<b>ADJUNTO PDF:</b>	<input checked="" type="checkbox"/> SI	<input type="checkbox"/> NO	
<b>CONTACTO CON AUTOR/ES:</b>	<b>Teléfono:</b> +593-982259301	<b>E-mail:</b> mcparedes19@gmail.com	
<b>CONTACTO CON LA INSTITUCIÓN (COORDINADOR DEL PROCESO UTE)::</b>	<b>Nombre:</b> Romero Paz Manuel de Jesús		
	<b>Teléfono:</b> +593-994606932		
	<b>E-mail:</b> manuel.romero@cu.ucsg.edu.ec		
<b>SECCIÓN PARA USO DE BIBLIOTECA</b>			
<b>Nº. DE REGISTRO (en base a datos):</b>			
<b>Nº. DE CLASIFICACIÓN:</b>			
<b>DIRECCIÓN URL (tesis en la web):</b>			