

**UNIVERSIDAD NACIONAL  
“SANTIAGO ANTÚNEZ DE MAYOLO”**

**FACULTAD DE CIENCIAS  
ESCUELA PROFESIONAL DE ESTADÍSTICA E  
INFORMÁTICA**



**Perceptrón multicapa de una red neuronal artificial y su aplicación  
en la predicción del turismo en el departamento de Ancash, 2018**

**Tesis para Optar el Título de:**

**Licenciado en Estadística e Informática**

**Bach. Gary Roosevelt Gomero Córdova**

**Bach. César Eduardo Vidal Robles**

**Asesor: Dr. Roger Pedro Norabuena Figueroa**

**HUARAZ - ANCASH - PERÚ**

**2019**

**FORMATO DE AUTORIZACIÓN PARA LA PUBLICACIÓN DE TRABAJOS DE INVESTIGACIÓN,  
CONDUCENTES A OPTAR TÍTULOS PROFESIONALES Y GRADOS ACADÉMICOS EN EL  
REPOSITORIO INSTITUCIONAL.**

**1. Datos del autor:**

Apellidos y nombres: Vidal Robles Cesar Eduardo

Código de alumno: 122.0403.053 Teléfono: 953546932

Correo electrónico: cesarvidalrobles@hotmail.com DNI o Extranjería: 71858362

(En caso haya más autores, llenar un formulario por autor)

**2. Tipo de trabajo de investigación:**

- Tesis  Trabajo de Suficiencia Profesional  
 Trabajo Académico  Trabajo de Investigación  
 Tesinas (presentadas antes de la publicación de la Nueva Ley Universitaria 30220 – 2014)

**3. Título Profesional o Grado obtenido:**

Licenciado en Estadística e Informática

**4. Título del trabajo de investigación:**

Perceptron Multicapa de una Red Neuronal Artificial en la Predicción del Turismo del  
Departamento de Ancash, 2018

**5. Facultad de:** CIENCIAS

**6. Escuela, Carrera o Programa:** ESTADISTICA E INFORMATICA

**7. Asesor:**

Apellidos y nombres NORABUENA FIGUEROA ROGER PEDRO Correo electrónico: rnorabuenaf@unasam.edu.pe

Teléfono: 968850116 N° de DNI o Extranjería: 41493243 ORCID: 0000-0003-3731-9843

**8. Tipo de acceso al Documento**

- Acceso público\* al contenido completo.  
 Acceso restringido\*\* al contenido completo

Si el autor eligió el tipo de acceso abierto o público, otorga a la Universidad Santiago Antúnez de Mayolo una licencia no exclusiva, para que se pueda hacer arreglos de forma en la obra y difundirlo en el Repositorio Institucional, respetando siempre los Derechos de Autor y Propiedad Intelectual de acuerdo y en el Marco de la Ley 822.

En caso de que el autor elija la segunda opción, es necesario y obligatorio que indique el sustento correspondiente:

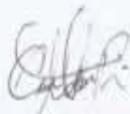
---

---

---

### 10. Originalidad del archivo digital

Por el presente dejo constancia que el archivo digital que entrego a la Universidad, como parte del proceso conducente a obtener el título profesional o grado académico, es la versión final del trabajo de investigación sustentado y aprobado por el Jurado.



Firma del autor

### 11. Otorgamiento de una licencia *CREATIVE COMMONS*

Para las investigaciones que son de acceso abierto se les otorgó una licencia *Creative Commons*, con la finalidad de que cualquier usuario pueda acceder a la obra, bajo los términos que dicha licencia implica.



*El autor, por medio de este documento, autoriza a la Universidad, publicar su trabajo de investigación en formato digital en el Repositorio Institucional, al cual se podrá acceder, preservar y difundir de forma libre y gratuita, de manera íntegra a todo el documento.*

Según el inciso 12.2, del artículo 12° del Reglamento del Registro Nacional de Trabajos de Investigación para optar grados académicos y títulos profesionales - RENATI "Las universidades, instituciones y escuelas de educación superior tienen como obligación registrar todos los trabajos de investigación y proyectos, incluyendo los metadatos en sus repositorios institucionales precisando si son de acceso abierto o restringido, los cuales serán posteriormente recolectados por el Recolector Digital RENATI, a través del Repositorio ALICIA".

### 12. Para ser llenado por la Dirección del Repositorio Institucional

Fecha de recepción del documento por el Repositorio Institucional:

18/01/2021

Firma:



**\*Acceso abierto:** uso lícito que confiere un titular de derechos de propiedad intelectual a cualquier persona, para que pueda acceder de manera inmediata y gratuita a una obra, datos procesados o estadísticas de monitoreo, sin necesidad de registro, suscripción, ni pago, estando autorizada a leerla, descargarla, reproducirla, distribuirla, imprimirla, buscarla y enlazar textos completos (Reglamento de la Ley No 30035).

**\*\* Acceso restringido:** el documento no se visualizará en el Repositorio.

**FORMATO DE AUTORIZACIÓN PARA LA PUBLICACIÓN DE TRABAJOS DE INVESTIGACIÓN,  
CONDUCTENTES A OPTAR TÍTULOS PROFESIONALES Y GRADOS ACADÉMICOS EN EL  
REPOSITORIO INSTITUCIONAL.**

**1. Datos del autor:**

Apellidos y nombres: Gomero Cordova Gary Roosevelt

Código de alumno: 02.0390.9.AR Teléfono: 942838688

Correo electrónico: garyroosv@hotmail.com DNI o Extranjería: 31682548

(En caso haya más autores, llenar un formulario por autor)

**2. Tipo de trabajo de investigación:**

- Tesis  Trabajo de Suficiencia Profesional  
 Trabajo Académico  Trabajo de Investigación  
 Tesinas (presentadas antes de la publicación de la Nueva Ley Universitaria 30220 – 2014)

**3. Título Profesional o Grado obtenido:**

Licenciado en Estadística e Informática

**4. Título del trabajo de investigación:**

Perceptron Multicapa de una Red Neuronal Artificial en la Predicción del Turismo del  
Departamento de Ancash, 2018

**5. Facultad de:** CIENCIAS

**6. Escuela, Carrera o Programa:** ESTADISTICA E INFORMATICA

**7. Asesor:**

Apellidos y nombres NORABUENA FIGUEROA ROGER PEDRO Correo electrónico: rnorabuenaf@unasam.edu.pe

Teléfono: 968850116 N° de DNI o Extranjería: 41493243 ORCID: 0000-0003-3731-9843

**8. Tipo de acceso al Documento**

- Acceso público\* al contenido completo.  
 Acceso restringido\*\* al contenido completo

Si el autor eligió el tipo de acceso abierto o público, otorga a la Universidad Santiago Antúnez de Mayolo una licencia no exclusiva, para que se pueda hacer arreglos de forma en la obra y difundirlo en el Repositorio Institucional, respetando siempre los Derechos de Autor y Propiedad Intelectual de acuerdo y en el Marco de la Ley 822.

En caso de que el autor elija la segunda opción, es necesario y obligatorio que indique el sustento correspondiente:

---

---

---

## 10. Originalidad del archivo digital

Por el presente dejo constancia que el archivo digital que entrego a la Universidad, como parte del proceso conducente a obtener el título profesional o grado académico, es la versión final del trabajo de investigación sustentado y aprobado por el Jurado.



Firma del autor

## 11. Otorgamiento de una licencia *CREATIVE COMMONS*

Para las investigaciones que son de acceso abierto se les otorgó una licencia *Creative Commons*, con la finalidad de que cualquier usuario pueda acceder a la obra, bajo los términos que dicha licencia implica.



*El autor, por medio de este documento, autoriza a la Universidad, publicar su trabajo de investigación en formato digital en el Repositorio Institucional, al cual se podrá acceder, preservar y difundir de forma libre y gratuita, de manera íntegra a todo el documento.*

Según el inciso 12.2, del artículo 12° del Reglamento del Registro Nacional de Trabajos de Investigación para optar grados académicos y títulos profesionales - RENATI "Las universidades, instituciones y escuelas de educación superior tienen como obligación registrar todos los trabajos de investigación y proyectos, incluyendo los metadatos en sus repositorios institucionales precisando si son de acceso abierto o restringido, los cuales serán posteriormente recolectados por el Recolector Digital RENATI, a través del Repositorio ALICIA".

## 12. Para ser llenado por la Dirección del Repositorio Institucional

Fecha de recepción del documento por el Repositorio Institucional:

18/01/2021

Firma:



**\*Acceso abierto:** uso lícito que confiere un titular de derechos de propiedad intelectual a cualquier persona, para que pueda acceder de manera inmediata y gratuita a una obra, datos procesados o estadísticas de monitoreo, sin necesidad de registro, suscripción, ni pago, estando autorizada a leerla, descargarla, reproducirla, distribuirla, imprimirla, buscarla y enlazar textos completos (Reglamento de la Ley No 30035).

**\*\* Acceso restringido:** el documento no se visualizará en el Repositorio.



## ACTA DE SUSTENTACIÓN DE TESIS

Los Miembros del Jurado de la Revisión y Sustentación de Tesis de la Escuela Académico Profesional de Estadística e Informática de la Facultad de Ciencias, designados mediante Resolución de Consejo de Facultad N° 151-2018-UNASAM-FC, se reunieron el día martes 17 de diciembre de 2019, a horas 10:00 a.m. en el Auditorio de la Facultad de Ciencias en acto público para evaluar la Sustentación de Tesis, presentado por los:

➤ **Bachilleres :**

- GOMERO CORDOVA GARY ROOSVELT
- VIDAL ROBLES CÉSAR EDUARDO

Tesis Titulada : "PERCEPTRON MULTICAPA DE UNA RED NEURONAL ARTIFICIAL Y SU APLICACIÓN EN LA PREDICCIÓN DEL TURISMO EN EL DEPARTAMENTO DE ANCASH, 2018".

Después de la Sustentación y las respuestas a las preguntas, el Jurado lo declara APROBADO para optar el Título Profesional de Licenciado en Estadística e Informática, con el calificativo de DIECISIETE (17)

En señal de conformidad y para constancia, firmamos la presente ACTA, siendo las 11:05 a.m. del mismo día y año.

Huaraz, 17 de diciembre de 2019.

MSc. FERNANDO RAÚL ARCE ZUÑIGA  
PRESIDENTE

Dra. ROSA VÍLCHEZ VÁSQUEZ  
SECRETARIA

Dr. ÁNGEL DECIDERIO MENDOZA LOPEZ  
VOCAL

Dr. ROGER PEDRO NORABUENA FIGUEROA  
ASESOR





## **DEDICATORIA**

A Dios, nuestros padres, hermanos y familiares quienes con su apoyo desinteresado y motivación incondicional impulsaron la culminación de nuestra carrera profesional.

Gary y César

## **AGRADECIMIENTO**

El agradecimiento eterno a la Universidad Nacional Santiago Antúnez de Mayolo, docentes y autoridades de la escuela académico profesional de Estadística e Informática, quienes nos guiaron por la senda de nuestra vida académica, inculcándonos conocimiento, valores para ser buenas personas y profesionales, al beneficio de la sociedad y del país.

Gary y César

## ÍNDICE

DEDICATORIA .....	ii
AGRADECIMIENTO .....	iii
ÍNDICE .....	iv
ABSTRACT.....	vii
RESUMEN .....	viii
INTRODUCCIÓN .....	ix
CAPÍTULO I: EL PROBLEMA.....	11
1.1. SELECCIÓN DEL PROBLEMA.....	12
1.2. JUSTIFICACIÓN DEL ESTUDIO .....	14
1.3. OBJETIVOS DE LA INVESTIGACIÓN .....	15
1.3.1. GENERAL .....	15
1.3.2. ESPECÍFICOS .....	15
CAPÍTULO II: MARCO TEÓRICO CONCEPTUAL.....	16
2.1. ANTECEDENTES DEL PROBLEMA.....	17
2.2. PLANTEAMIENTO TEÓRICO ATINGENTE.....	32
2.2.1. Bases teóricas .....	32
2.2.2. Definición de términos .....	61

CAPÍTULO III: HIPÓTESIS Y OPERACIONALIZACIÓN DE VARIABLES ...	63
3.1. Hipótesis .....	64
3.2. Operacionalización de variables .....	64
CAPÍTULO IV: METODOLOGÍA .....	65
4.1. Materiales y lugar de ejecución .....	66
4.1.1. Lugar .....	66
4.1.2. Materiales .....	66
4.1.3. Equipos.....	66
4.1.4. Recurso humano.....	66
4.2. Métodos.....	66
CAPÍTULO V: ANÁLISIS Y DISCUSIÓN DE RESULTADOS .....	69
5.1. Análisis de los datos.....	70
5.2. Discusión de resultados.....	88
CAPÍTULO VI: CONCLUSIONES, LIMITACIONES Y RECOMENDACIONES .....	92
CONCLUSIONES .....	93
LIMITACIONES .....	94
RECOMENDACIONES.....	95
REFERENCIAS BIBLIOGRÁFICAS.....	96

ANEXOS ..... 100

## **ABSTRACT**

The present thesis work according to its design is non-experimental, longitudinal, time series type and aimed to evaluate the predictive capacity of the multilayer perceptron of an artificial neural network applied to tourism in the department of Ancash, 2018, according to the arrival records to the lodging establishments, which are in the INEI databases.

The architecture of the artificial neural network is composed of 12 input variables lagging in time and one output variable, with multilayer and backpropagation model, with logistic activation function, with two hidden layers of 9 and 1 neuron respectively, and a threshold of detention of 0.01. The training algorithm is composed of 80% of the time series data and 20% for the validation sample. The artificial neural network model is valid since it presented a threshold of 0.008394336 which is lower than the 0.01 threshold of the initial architecture, in addition to presenting an error of only 0.091085 and a predictive capacity of  $R^2 = 0.968$ , this being a very good Fit to time series data.

**Keywords:** Multilayer perceptron, artificial neural network, time series.

## RESUMEN

El presente trabajo de tesis según su diseño fue no experimental, longitudinal de tipo serie de tiempo y tuvo por objetivo evaluar la capacidad predictiva del perceptrón multicapa de una red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018, según los registros de arribos a los establecimientos de hospedaje, que se encontraron en las bases de datos del INEI.

La arquitectura de la red neuronal artificial estuvo compuesta por 12 variables entrada rezagadas en el tiempo y una variable de salida, con modelo de multicapa y retropropagación, con función de activación logístico, con dos capas ocultas de 9 y 1 neurona respectivamente, y un umbral de detención del 0.01. El algoritmo de entrenamiento estuvo compuesto por el 80% de los datos de la serie temporal y del 20% para la muestra de validación. El modelo de red neuronal artificial fue válido debido a que presentó un umbral de 0.008394336 lo cual fue inferior al umbral 0.01 de la arquitectura inicial, además de presentar un error de tan solo 0.091085 y una capacidad predictiva de  $R^2 = 0.968$ , siendo este un muy buen ajuste a los datos de la serie temporal.

Palabras Clave: Perceptrón multicapa, red neuronal artificial, series de tiempo.

## **INTRODUCCIÓN**

El presente trabajo de tesis fue el resultado de mucha dedicación, esfuerzo y tiempo en la búsqueda de los datos, procesamiento de los datos, para ser analizados mediante el modelo de perceptrón multicapa de una red neuronal artificial.

Con el presente trabajo de tesis se pretendió evaluar la capacidad predictiva del perceptrón multicapa de una red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018

Para ello en el capítulo 1, se resalta la descripción del problema de estudio, se muestra en la justificación la importancia que tendrá este trabajo de investigación, y se plantean los objetivos que sirvieron de guías para la realización de la investigación.

En el capítulo 2, se mostraron antecedentes, en la que resaltan los estudios del uso del perceptrón multicapa de una red neuronal artificial. Así mismo, se presenta de manera estructurada el desarrollo de la variable de estudio, con sus respectivas teorías que la fundamentan.

En el capítulo 3, se presentaron la hipótesis del presente trabajo de investigación y se realiza la operacionalización de la variable estudiada.

En el capítulo 4, se detallaron aspectos metodológicos del presente trabajo de investigación. Así, el lugar de ejecución fue Instituto Nacional de Estadística e

Informática, con diseño de investigación de no experimental, longitudinal de tipo serie de tiempo, con una muestra de los registros de arribos a los establecimientos de hospedaje de enero del 2003 hasta diciembre de 2017.

En el capítulo 5, se mostraron los procedimientos paso a paso para la aplicación del modelo perceptrón multicapa de una red neuronal artificial, así como el análisis descriptivo respectivo de cada una de las características estudiadas.

Finalmente, en el capítulo 6, se mostraron las conclusiones del presente trabajo de investigación y se siguieron recomendaciones que puedan ayudar a una mejor toma de decisiones.

## **CAPÍTULO I: EL PROBLEMA**

## **1.1. SELECCIÓN DEL PROBLEMA**

La predicción de series de tiempo o predicción de series temporales es un área de investigación de mucho interés que está en desarrollo desde hace varias décadas. En especial, en las últimas tres décadas ha aumentado el interés en esta área dado el progreso en las tecnologías de información, específicamente las mejores capacidades de procesamiento por parte de los computadores, lo cual permite realizar cálculos complejos en algunos minutos o incluso en algunos segundos. Este aumento de interés se ve reflejado por la diversidad de sus aplicaciones en diferentes disciplinas variando desde la economía a la ingeniería, donde la predicción de series de tiempo es un campo de investigación activo e importante actualmente y se estima que lo continuará siendo en el futuro (Zhang, 2004).

La gran importancia que tiene el llevar a cabo predicciones precisas de los valores futuros, hacen necesario dedicar recursos en la investigación para la obtención de herramientas de pronósticos más exactos. Una predicción más precisa en la demanda de un producto permitirá optimizar la cadena de abastecimiento y de esta forma tener en stock la cantidad necesaria para vender sin perder ventas ni tampoco almacenar en bodega productos que no serán necesarios. Una mejor predicción del consumo de electricidad para una región es vital dado que ayudará en la toma de decisiones sobre qué cantidad producir para un lugar determinado en un periodo específico, utilizando los recursos energéticos necesarios minimizando costos operacionales para las estaciones eléctricas. De la misma forma, una predicción precisa de los índices

bursátiles en el futuro permitirá tomar decisiones sobre la venta o compra de acciones en el momento exacto (Escobar, Valdes, & Zapata, 2009).

Así mismo, las redes neuronales artificiales han surgido como una importante herramienta de modelado cuantitativo con poderosas capacidades de clasificación y predicción de patrones de comportamiento en muchos campos de los negocios, la industria y la ciencia (Zhang, 2004). Así, una de las principales áreas de aplicación de las redes neuronales artificiales son los pronósticos, ya que, la capacidad de predecir con exactitud el futuro es fundamental para muchos procesos de decisión en planificación, programación, compras, formulación de estrategias, creación de políticas y operaciones de la cadena de suministro. La característica de las redes neuronales artificiales es aprender de los datos o de la experiencia, teniendo además una capacidad de aproximación funcional con precisión a muchas relaciones funcionales complejas, siendo así, las redes neuronales artificiales una herramienta de modelado muy general y flexible para los pronósticos de las series de tiempo.

Por otro lado, el departamento de Ancash debe diversificar su economía apostando principalmente en el desarrollo del turismo, aprovechando el crecimiento del Perú, que ofrece oportunidades de apertura comercial, incremento en las inversiones y el incremento del turismo receptivo e interno lo cual permita el desarrollo de la oferta turística, aprovechando los potenciales de la región para convertirse en un importante destino turístico de la región. Lo indicado anteriormente, enfatiza la necesidad de

contar con predicciones precisas y para éste caso en particular respecto al turismo en el departamento de Ancash, donde los entes encargados de dicha actividad no cuentan con modelos avanzados de pronóstico, y sus predicciones se basan únicamente en estadísticas descriptivas las cuales son tomadas como predicciones futuras, ocasionando una ineficaz distribución de los recursos para tal fin.

Por todo lo mencionado anteriormente, se planteó la siguiente pregunta de investigación:

**¿Cuál es la capacidad predictiva del perceptrón multicapa de una red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018?**

## **1.2.JUSTIFICACIÓN DEL ESTUDIO**

El presente trabajo de tesis fue de gran importancia para las autoridades del MINCETUR y PROMPERÚ para el planteamiento de políticas que contribuyan el desarrollo del turismo receptivo y del turismo interno en el departamento de Ancash.

Por otro lado, el trabajo de investigación fue de gran importancia para las agencias de viajes y operadores turísticos, pues conocieron los futuros patrones de comportamiento del turismo en el departamento de Ancash, y puedan con ello prever los bienes y servicios necesarios para satisfacer a la demanda turística.

Así mismo, fue de gran importancia para los estudiantes e investigadores del área de la estadística e informática, pues tienen a la mano los procedimientos en la aplicación del perceptrón multicapa de una red neuronal artificial en la predicción del turismo en el departamento de Ancash.

### **1.3.OBJETIVOS DE LA INVESTIGACIÓN**

#### **1.3.1. GENERAL**

Evaluar la capacidad predictiva del perceptrón multicapa de una red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018.

#### **1.3.2. ESPECÍFICOS**

- Diseñar la arquitectura de la red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018.
- Establecer el algoritmo de entrenamiento de la red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018.
- Determinar la validación del proceso de aprendizaje de la red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018.

## **CAPÍTULO II: MARCO TEÓRICO CONCEPTUAL**

## **2.1. ANTECEDENTES DEL PROBLEMA**

Sánchez & Velásquez, 2010, en su trabajo de investigación titulado “Problemas de investigación en la predicción de series de tiempo con redes neuronales artificiales” desarrollado en Colombia, concluyeron en que la literatura evidencia un creciente interés por la realización de modelos de redes neuronales que conduzcan a resultados cada vez más acertados en el ajuste, favorecido por sus características de adaptabilidad, no linealidad y habilidad para aprender comportamientos desconocidos. Si bien se reconoce que hay mucha experiencia ganada en estos modelos, existen muchos factores que pueden afectar su desempeño, y los estudios empíricos a menudo encontrados no son suficientes para dirigir una solución al problema, donde se limita el proceso de modelado a técnicas ad-hoc, en lugar de acercamientos científicos que sigan una metodología y proceso de modelado replicable.

Escobar, Valdes & Zapata (2009), en su trabajo de investigación titulado “Redes Neuronales Artificiales en predicción de Series de Tiempo. Una aplicación a la Industria. Buenos Aires – Argentina”, desarrollado en Argentina, consideraron que los modelos de redes neuronales son capaces de predecir el futuro de acuerdo a los periodos pasados. Así mismo, dan cuenta que las redes neuronales presentan una gran capacidad de predicción de las series de tiempo obteniéndose errores absolutos medios porcentuales inferiores al 5%.

Villada, Muñoz, & García-Quintero (2016), en su trabajo de investigación titulado “Redes Neuronales Artificiales aplicadas a la Predicción del Precio del Oro”, desarrollado en Colombia, concluyeron que los resultados mostrados en la predicción del precio del oro confirman la aplicabilidad de las Redes Neuronales Artificiales (RNA) al mercado de bienes básicos. Se destaca la capacidad de estas redes para modelar sistemas complejos y obtener menores errores tanto en el entrenamiento como en la predicción. El modelo obtenido se convierte en una herramienta de utilidad para gobiernos, bancos centrales y operadores de corto plazo; pues entrega señales de precios que permiten planear compras y ventas del metal precioso con mejor precisión que la arrojada por otros modelos. Así mismo, se encontraron mejores resultados al incluir otras variables explicativas que tienen en cuenta la aversión al riesgo.

Jiménez-Carrión, Gutiérrez-Segura & Celi-Pinzón (2018), en su trabajo de investigación titulado “Modelado y Predicción del Fenómeno El Niño en Piura, Perú mediante Redes Neuronales Artificiales usando Matlab”, desarrollado en Perú, concluyeron que las redes neuronales son una técnica altamente confiable para encontrar un patrón de comportamiento de las precipitaciones y luego para predecir el fenómeno alcanzando una tasa de acierto del 98.4% en la etapa de entrenamiento y de 100% en la predicción del primer semestre del año 2016.

Faraway & Chatfield (1998), en su trabajo de investigación titulado “*Time series forecasting with neural networks: a comparative study using the airline data*”

desarrollado en Estados Unidos, concluyeron en que hay muchas posibilidades de equivocarse con el modelado de redes neuronales (como ocurre con muchas otras técnicas estadísticas sofisticadas). Sin una elección cuidadosa de la arquitectura, las funciones de activación y los valores de inicio apropiados para los pesos, las rutinas de ajuste pueden no converger, pueden converger a un mínimo local o pueden llevar a pronósticos que no son razonables. Agregar unidades ocultas adicionales aumenta el número de parámetros en un modelo de redes neuronales. Esto puede llevar a una mejora en el ajuste, pero puede llevar a un deterioro en las predicciones fuera de la muestra.

Zhang, Patuwo, & Hu (1998), en su trabajo de investigación titulado “Forecasting With Artificial Neural Networks: The State of the Art”, desarrollado en Estados Unidos, concluyeron que las características únicas de las redes neuronales artificiales (ANN): adaptabilidad, no linealidad, capacidad de mapeo de funciones arbitrarias las hacen bastante adecuadas y útiles para las tareas de pronóstico. En general, las ANN dan un desempeño satisfactorio en el pronóstico. Para utilizar mejor las ANN para los problemas de pronóstico y otras tareas, es importante comprender las limitaciones de las ANN, lo que pueden hacer y lo que no pueden hacer. Varios puntos deben ser enfatizados: Los ANN son métodos no lineales por sí mismo. Para procesos lineales estáticos con poca perturbación, pueden no ser mejores que los métodos estadísticos lineales. Los ANN son métodos de caja negra. No hay una forma explícita para explicar y analizar la relación entre entradas y salidas. Esto causa dificultad en la

interpretación de resultados de las redes. Tampoco se pueden utilizar métodos de prueba estadísticos formales para las ANN. Los ANN son propensos a tener problemas de sobrealimentación debido a su gran conjunto de parámetros típicos para ser estimados. No hay métodos estructurados hoy en día para identificar qué estructura de red puede aproximarse mejor a la función, mapeando las entradas a las salidas. Por lo tanto, los experimentos tediosos y los procedimientos de prueba y error se utilizan a menudo. Las ANN generalmente requieren más datos y tiempo de computadora para la capacitación.

Álvarez, Lau, Pérez, & Leyva (2016), en su trabajo de investigación titulado “Predicción de resultados académicos de estudiantes de informática mediante el uso de redes neuronales”, desarrollado en Cuba, concluyeron que para obtener respuestas de una red neuronal que se asemejen lo más posible a los valores correctos es necesaria una adecuada selección de la arquitectura de la red a utilizar, así como del algoritmo de aprendizaje que se ejecutará. También, para la aplicación correcta de las RNA a una determinada situación, se hace necesario una correcta selección de las variables a utilizar y su codificación. El ajuste de las predicciones de las redes neuronales a las estadísticas significativas de la muestra de datos seleccionada, constituye una condición para validar que las redes neuronales se encuentran bien entrenadas y que son capaces de realizar predicciones correctas.

Acosta-Cervantes, Villarreal-Marroquín, & Cabrera-Ríos (2013), en su trabajo de investigación titulado “Estudio de validación de un método para seleccionar técnicas de pronóstico de series de tiempo mediante redes neuronales artificiales” desarrollado en México consideran que una red neuronal artificial (RNA) en el contexto del método propuesto, es en esencia un modelo matemático no lineal que contiene parámetros conocidos como “pesos”. Cuántos más pesos tenga una RNA, mayor no linealidad se podrá representar con ella. Para encontrar estos pesos se utilizan algoritmos de optimización que minimizan una función de errores cuadrados de aproximación. En el área de RNA, varios de estos algoritmos son llamados algoritmos de retropropagación, así como encontrar un conjunto de pesos que permitan una aproximación adecuada a datos conocidos se le denomina entrenamiento. Para ello se utilizan tres pasos: escalar los datos al intervalo  $[-1, 1]$ , caracterizar la serie de tiempo y someter a la red neuronal artificial.

Ortiz (2017), en su trabajo de investigación titulado “Pronóstico de precios de petróleo: una comparación entre modelos GARCH (Autorregresivo heterocedástico generalizado) y redes neuronales diferenciales” desarrollado en México, concluyó en que mediante el análisis de las series de precios de cierre de los precios de barriles de petróleo crudo se pudo comprobar que las redes neuronales diferenciales pueden ser adoptadas como una técnica de cálculo de pronósticos comparables, e incluso superior en su desempeño, a las técnicas basadas en modelos de la familia GARCH. El uso de un modelo de RND (redes neuronales diferenciales) para llevar a cabo pronósticos de

valores futuros de una serie de tiempo no lineal es mucho más simple que realizar pronósticos mediante modelos de la familia GARCH por ser bastante laboriosos, mientras que en las RND se usa un solo modelo, al cual se alimenta con los valores históricos que se van ajustando sus valores hasta llegar al valor buscado, de acuerdo al criterio de convergencia.

Camarena, Del Castillo, Ramírez, & Zambrano (2013), en su trabajo de tesis titulado “Una Revisión Literaria del Impacto del Turismo en el Desarrollo Económico” para obtener el grado de maestro en administración estratégica de empresas de la Pontificia Universidad Católica del Perú, concluyeron que el turismo es una actividad económica que tiene influencia multisectorial debido a que su crecimiento impacta en sectores económicos, sociales, políticos y medio ambientales tales como (a) empleo, (b) hotelería y restaurantes, (c) ecosistema, (d) infraestructura, etc.. El turismo a lo largo de las últimas décadas ha tenido una evolución importante, es por esta razón que la mayoría de países compiten entre sí con el objetivo de ser un destino turístico atractivo que le permita obtener mayor cantidad de turistas y con ello generar mayores ingresos económicos. El desarrollo del turismo en países en vías de desarrollo (como el Perú) comienza por establecer una visión holística del turismo, la cual constituya claramente los objetivos y metas a desarrollar, para poder lograr el crecimiento económico del país. Cabe resaltar la importancia y necesidad de participación activa e involucramiento de todos los participantes directos e indirectos de la oferta turística, lo cual permitirá lograr una mejor planificación en el desarrollo de esta actividad

económica. Si bien el turismo genera ingresos económicos, es necesario que el gobierno vele por la reinversión de un porcentaje de las ganancias generadas dentro de la localidad, esto con la finalidad de mantener vigente el destino turístico (infraestructura, comunicaciones, etc.), así como mejorar los ingresos y la calidad de vida de los habitantes, con lo cual se contribuya al desarrollo personal de estas personas. Los gobiernos regionales deben tener una función específica de velar por el desarrollo del turismo, manteniendo como objetivo el evitar la depredación de los recursos naturales que afecten la biodiversidad del ecosistema del destino turístico. Continuar sin un control estricto de estos recursos generará en el corto y mediano plazo la incapacidad de ser atractivo al destino turístico afectando la economía y puestos de trabajo que genera directa e indirectamente el turismo.

Valencia, Vanegas, Correa, & Restrepo. (2017), en su trabajo de investigación titulado “Comparación de pronósticos para la dinámica del turismo en Medellín, Colombia”, concluyeron que se encontraron modelos con adecuada representación de la variación temporal de las series de turistas que llegan a Medellín, colombianos o extranjeros, diferentes a los modelos clásicos, basados en Estadística Bayesiana. Así mismo, se hallaron indicios de comportamientos estacionales, reflejados en la presencia de la variable indicadora mes, además, se encontró un impacto significativo del valor de turistas rezagado de orden 1, para explicar el comportamiento de la cantidad de ambos tipos de turistas que llegan a esta ciudad, es decir, tiene una

dependencia temporal de primer orden. Esto permitió caracterizar el comportamiento de este sector de la economía colombiana, y con ello, ayudar en la planeación de dicho sector. Al usar los indicadores de errores SMAPE (Error porcentual absoluto medio simétrico) y RMSE (Raíz del error cuadrático medio) que son muy útiles en casos generales, en especial robustos cuando las respuestas se acercan a cero- se corrobora que el indicador MAPE (Error porcentual absoluto medio) puede ser apropiado, pero solo en casos en los que los datos toman valores muy altos, como se ve en este trabajo, alrededor de 5000 o más turistas por mes. La variable mes también es una variable estadísticamente significativa en las demandas de turismo de colombianos y extranjeros, resultado que permite identificar los periodos de mayor incidencia para la planeación de recursos hoteleros. Por ejemplo, para los colombianos, las vacaciones entre diciembre-enero y junio-julio representan temporadas para visitar la ciudad de Medellín, y anualmente se repite dicho comportamiento. Las asociaciones negativas, encontradas con los gastos energéticos, podrían deberse a diversas razones, una de ellas puede ser que los periodos de mayor flujo turístico son las vacaciones de los sectores educativos; sin embargo, es necesario usar otro tipo de técnicas investigativas para determinar si hay algún grado de disminución de actividades o alguna otra razón. Puede considerarse para futuros estudios la planeación de disponibilidad de hoteles en la ciudad, analizando la incidencia del mes, dados los resultados de éste estudio. Con ello, se puede requerir mayores recursos en los meses encontrados con mayor incidencia de los turistas extranjeros, como son: julio, agosto y diciembre, temporadas en que también se programan eventos de ciudad como la feria de las flores, en agosto,

y los alumbrados, en diciembre. Por todo esto es importante programar estrategias de atención y cobertura de los servicios requeridos por este tipo de turistas.

Barbachán, Fretelli, Rojas, & Tafur (2017), en su trabajo de tesis titulado “Planeamiento Estratégico para la Industria Peruana de Turismo” para obtener el grado de maestro en administración estratégica de empresas de la Pontificia Universidad Católica del Perú, concluyeron que la industria turística del Perú tiene un gran potencial para desarrollar; se encuentra favorecido por la ubicación geográfica, biodiversidad climática, riqueza de flora y fauna, culturas milenarias, gastronomía de fama mundial y restos arqueológicos de valor histórico. El sector privado que conforma la industria del turismo peruano no son proactivas en el desarrollo de estrategias que permitan el crecimiento de la industria; y se encuentran a la espera de las iniciativas y proyectos que emprende el gobierno central para impulsarla. La inversión en tecnología e innovación es insuficiente a nivel de país e industria. Lo cual, disminuye la atraktividad, pues es un factor clave de la competitividad del turismo a nivel mundial y es la mejor forma de optimizar costos en los procesos, componentes de la cadena de valor. La industria del turismo peruano no se adapta oportunamente a los cambios de la demanda global turística, ni a la exigencia del turista moderno, en cuanto a preferencias como: lujo, bienestar, comunicaciones y otros. Con lo cual, se pierde la oportunidad de captar estos nichos de mercado.

Cárdenas, Sánchez, Soria, & Vargas (2017), en su trabajo de tesis titulado “Planeamiento Estratégico del Sector Turismo en la Región Ancash” para obtener el grado de maestro en administración estratégica de empresas de la Pontificia Universidad Católica del Perú, concluyeron que la visión del sector turismo de Ancash para el año 2025 contempla el accionar del sector de manera integrada para ofrecer experiencias inolvidables a los visitantes al contar con infraestructura de calidad y personal calificado. En la actualidad, la región cuenta con una visión, desde el punto de vista de la municipalidad departamental, y con un enfoque generalizado y no específico para el sector turismo dentro del marco de este plan estratégico, se ha definido que el Sector Turismo en la Región Ancash constituye un destino turístico atractivo para nacionales y extranjeros, en base a sus riquezas naturales y culturales, que serán explotadas de manera sostenible por empresas autorizadas, las cuales ofrecerán hospedajes de calidad, con operadores turísticos experimentados y serviciales, y brindarán acceso fácil y servicios de telecomunicaciones eficientes, lo cual generará ingresos para las distintas comunidades de la región. El Sector Turismo en la Región Ancash tiene la posibilidad de aprovechar diversas oportunidades que le brinda el entorno. Estas son las siguientes: (a) marco legal que decreta a la actividad turística como prioritaria, (b) políticas que estimulan el turismo nacional, (c) PBI regional superior al promedio nacional y (d) sector turismo en crecimiento, entre otras. Al mismo tiempo, con este plan estratégico, se busca proteger al Sector Turismo en la Región Ancash de las siguientes amenazas: (a) disminución en la tasa de crecimiento económico anual, en la demanda interna y en el consumo privado; (b)

informalidad, que representa más del 50% de la fuerza laboral del país; (c) migración negativa en la región, y (d) daños al patrimonio cultural y natural por acciones irresponsables, entre otras. El Sector Turismo en la Región Ancash posee varias fortalezas. Entre ellas, se considera las siguientes: (a) es un empleador importante a nivel regional, (b) posee recursos hídricos y naturales, (c) dispone de riqueza cultural y natural con grandes atractivos, (d) alcanza un índice de visitas a monumentos y museos igual a 1.50 la cantidad de arribos, (e) existe un proyecto para ampliar la cobertura de la banda ancha de Internet y de celular en todos los distritos de la región, entre otras. Con el análisis realizado, se identificó cuatro debilidades. La principal consiste en que el sector está compuesto por diversidad de actores que no trabajan mancomunadamente. A esto se le suma las siguientes: (a) la mayoría de los establecimientos de hospedaje son “no categorizados”, (b) falta información financiera consolidada sobre el sector, y (c) se evidencia infraestructura vial deficiente a lo largo de todo el departamento. Las estrategias retenidas que se van a implementar son las que siguen: (a) desarrollar servicios de Internet para alcanzar a más turistas potenciales con atención personalizada; (b) penetrar en el mercado de turistas nacionales provenientes de Lima; (c) desarrollar el mercado de turistas extranjeros provenientes de China; (d) penetrar en el mercado de turistas extranjeros europeos; (e) desarrollar el mercado de turistas extranjeros de los Estados Unidos, (f) mejorar la infraestructura hotelera existente para que haya una oferta de hospedajes categorizados, y (g) desarrollar servicios de turismo ecológico.

Pachas & Vélchez (2015), en su trabajo de tesis titulado “Planeamiento Estratégico de la Industria Hotelera para el Turismo Receptivo” para obtener el grado de maestro en administración de negocios globales de la Pontificia Universidad Católica del Perú, concluyeron que la Industria Hotelera para el Turismo Receptivo se encuentra en una fase de crecimiento. Dependiendo del destino turístico, las propiedades hoteleras tienen en la mayoría de plazas, potencial para desarrollar ventajas competitivas. Existen plazas en la que la rivalidad es baja y/o la competencia en ciertas categorías es inexistente lo cual no incentiva la competitividad del Sector Industrial de la Industria Hotelera para el Turismo Receptivo ni sus participantes. El desarrollo de las ventajas competitivas depende a su vez del desarrollo de factores claves como: (a) gestión directiva, competitiva, y con visión a largo plazo; (b) liderazgo; (c) empleo de nuevas tecnologías e innovación para generar valor agregado; (d) la capacitación constante de todos los miembros de una organización hotelera; y (e) realizar prácticas éticas y socialmente responsables con stakeholders. La curva de aprendizaje para preparar un hotel para atender el turismo receptivo es significativa. La Industria Hotelera para el Turismo Receptivo tiene un alto potencial para aprovechar la ventaja comparativa del Perú (i.e., legado cultural y bellos paisajes naturales) para incursionar en destinos turísticos atendiendo en un inicio al viajero nacional y sus necesidades. Y a medida que el producto se consolide comenzar a atraer viajeros extranjeros a mediano plazo. Existe una alta concentración de viajeros provenientes de EE.UU. y Sudamérica. Sin embargo, el número de viajeros procedentes de otros destinos como

Asia y Oceanía se ha incrementado considerablemente en los últimos años. Esto expone una oportunidad para el Sector de diferenciarse en su propuesta. El desarrollo de la Industria Hotelera para el Turismo Receptivo podrá ser fomentado en la medida en que el Sector privado se organice y dialogue con las autoridades municipales y gubernamentales para lograr reducir las principales barreras que impiden o retrasan las inversiones hoteleras.

Camilo (2006), en su trabajo de investigación titulado “Predicción de series temporales con redes neuronales: una aplicación a la inflación colombiana”, desarrollado en Colombia, concluye que los resultados obtenidos ilustraron el uso de las redes neuronales en la predicción de series temporales. Un ejemplo aplicado sobre las variaciones en el índice de precios al consumidor (IPC) permitió observar que las predicciones obtenidas a través de redes neuronales tienden a ser más precisas que las originadas por metodologías tradicionales, como el suavizamiento exponencial y el método SARIMA de Box-Jenkins. Adicionalmente, la utilidad de las redes neuronales, en combinación con otras redes o metodologías tradicionales, se mostró efectiva en el proceso de predicción en términos del MSE (Error cuadrático medio). Finalmente, las redes neuronales sin la neurona de tendencia, en la mayoría de los casos exhibieron las menores medidas de error en la predicción, en comparación con la metodología utilizada que propone la tendencia como una neurona de entrada. En todos los casos se estimaron y seleccionaron redes que tuvieran el mejor ajuste posible sobre el conjunto de entrenamiento y la menor medida de error de predicción sobre el

conjunto de validación con el fin de evitar el problema de subaprendizaje.

Andrés & Misas (2007), en su trabajo de investigación titulado “Evaluación de pronósticos del tipo de cambio utilizando redes neuronales y funciones de pérdida asimétricas”, concluyeron que este trabajo compara pronósticos provenientes de un modelo no lineal (Red Neuronal) con los de un modelo lineal tradicional (ARIMA). Los pronósticos se obtienen a través de una metodología de rolling y su evaluación se lleva a cabo con respecto a medidas tanto simétricas (las cuales asignan la misma valoración a errores de la misma magnitud sin importar su signo) como asimétricas (las cuales permiten diferenciar los errores dependiendo no solamente de su magnitud sino de su signo). La literatura siempre ha tenido la visión que los pronósticos no lineales, si son mejores para pronosticar, no lo son de una manera abrumadora con respecto a sus contrapartes lineales. Este argumento ha sido siempre esbozado utilizando para ello funciones de pérdida simétricas. Por lo anterior este trabajo presenta un esquema de la teoría de decisión y pronóstico en economía, con el fin de ilustrar las distintas posibilidades que existen para evaluar predicciones. De allí se concluyó que las funciones basadas en minimización de un error cuadrático medio son tan solo una de las muchas posibilidades existentes para evaluar la bondad de un pronóstico. Por lo anterior, en el presente documento se utilizaron, además de las medidas tradicionales, funciones de pérdida asimétricas con el fin de comparar, bajo este esquema, los pronósticos. Los resultados obtenidos permiten concluir que, a la

luz de las funciones de pérdida asimétricas, los modelos no lineales tienen una mejora considerable en capacidad de pronóstico, con respecto a los modelos lineales. Este resultado es robusto al horizonte de pronóstico, justificando así el uso de técnicas de estimación más complejas si lo que se necesita es solucionar un problema en el que el pronóstico óptimo deba ser evaluado con funciones de pérdida que no son simétricas.

Ospina & Zamprogno (2003), en su trabajo de investigación titulado “Comparacao de algumas tecnicas de previsao em analise de series temporais”, desarrollado en Colombia, concluyeron que los resultados obtenidos revelan que las previsiones de mejor calidad para la serie del PIB (Producto Bruto Interno) se obtienen a través del modelo de Holt-Winters con estacionalidad aditiva; en la clase de modelos SARIMA, las previsiones obtenidas con el modelo SARIMA(3,1,3)x(2,0,1) presentan un mejor comportamiento para largos períodos de predicción. De los modelos evaluados, el algoritmo de Holt-Winters con estacionalidad multiplicativa y el que presenta los mejores resultados de predicción. Además, el costo computacional de este algoritmo y mucho menor que los modelos de Box-Jenkins. El modelo seleccionado de redes neurales presenta un desempeño mejor para largos periodos de tiempo, pues parece que se ajusta más rápidamente los cambios estructurales a través del tiempo. En el análisis de la serie del IPC (Índice de Precios al Consumidor), observamos que la metodología de Holt-Winters se mostró superior al modelado de Box-Jenkins, donde el modelo de Holt-Winters con estacionalidad multiplicativa fue superior a todos los

demás modelos en análisis. Una alternativa interesante a ser analizada para un trabajo futuro de investigación y el de tratar de combinar las previsiones de una serie temporal bajo las metodologías tratadas en este trabajo con el fin de aumentar el poder predictivo y proporcionar previsiones más confiables.

## **2.2. PLANTEAMIENTO TEÓRICO ATINGENTE**

### **2.2.1. Bases teóricas**

#### **A. Turismo**

El turismo comprende las actividades que realizan las personas durante sus viajes y estancias en lugares distintos al de su entorno habitual, por un período de tiempo consecutivo inferior a un año con fines de ocio, por negocios y otros (Organización Mundial del Turismo, 2011). Se trata de una definición amplia y flexible, que concretiza las características más importantes del turismo. Éstas son:

- Introducción de los posibles elementos motivadores del viaje, “ocio, negocio, otros”
- Acotación temporal del período por un año, período realmente amplio, máxime si se compara con el tiempo normal de extensión de los visados de viaje para turismo por los gobiernos (tres meses) o con la periodificación prevista por algunas legislaciones para la delimitación de lo que se considera residencia habitual (seis meses).
- Delimitación de la actividad desarrollada antes y durante el periodo de la estancia.

- Localización de la actividad turística como la actividad realizada fuera de su entorno habitual.

El concepto del turismo está íntimamente ligado con la definición de turista, por lo tanto, lo podemos entender como el fenómeno que se presenta cuando uno o más individuos se trasladan a uno o más sitios diferentes de los de su residencia habitual por un periodo mayor a 24 horas y menor de 180 días, sin participar en los mercados de trabajo y capital de los sitios visitados. Los rasgos fundamentales del concepto anterior son los de traslado y estadía, sin tomar en cuenta el de motivación, debido a las características y modificaciones que frecuentemente vienen presentando en este aspecto los movimientos de viajeros. Además, como cualquier otra actividad económica, será la estructura de producción y de oferta la que finalmente habrá de definir al turismo dentro del contexto macroeconómico ya que, en el momento en que un individuo consume bienes o servicios de carácter turístico en una economía, bajo los requisitos señalados (traslado, estadía y no participación en los mercados de trabajo y capital de la misma), pasa a formar parte de la demanda propia de esta rama, independientemente de su motivación para hacerlo. Por ello, con base en la naturaleza de los demandantes, es posible establecer la connotación de turismo de acuerdo con los satisfactores que lo definen, y que en última instancia constituirán el objeto del análisis económico de esta actividad. Entonces, es indispensable definir bienes y servicios turísticos como todos aquéllos que sean necesarios o estén directamente. (Ibáñez & Cabrera, 2011)

### **A.1. El sistema turístico**

La naturaleza de la actividad turística es un resultado complejo de interrelaciones entre diferentes factores que hay que considerar conjuntamente desde una óptica sistemática, es decir, un conjunto de elementos interrelacionados entre sí que evolucionan dinámicamente (Organización Mundial del Turismo, 2011). Concretamente, se distinguen cuatro elementos básicos en el concepto de actividad turística:

1. La demanda: formada por el conjunto de consumidores –o posibles consumidores– de bienes y servicios turísticos.
2. La oferta: compuesta por el conjunto de productos, servicios y organizaciones involucrados activamente en la experiencia turística.
3. El espacio geográfico: base física donde tiene lugar la conjunción o encuentro entre la oferta y la demanda y en donde se sitúa la población residente, que, si bien no es en sí misma un elemento turístico, se considera un importante factor de cohesión o disgregación, según se la haya tenido en cuenta o no a la hora de planificar la actividad turística.
4. Los operadores del mercado: son aquellas empresas y organismos cuya función principal es facilitar la interrelación entre la oferta y la demanda. Entran en esta consideración las agencias de viajes, las compañías de transporte regular y aquellos organismos públicos y privados que, mediante su labor profesional, son artífices de la ordenación y/o promoción del turismo.

## **A.2. Demanda turística**

Bowles (2010) nos ofrece por exclusión una definición muy original de turista: La diferencia entre un turista y un viajero es que mientras el primero piensa en regresar desde el mismo momento de su llegada, el viajero puede no regresar nunca. Naturalmente la definición de Bowles, lejos de ser técnicamente perfecta, intenta resaltar el espíritu aventurero y abierto a nuevas experiencias del viajero sin destino fijo, no sometido a los circuitos organizados del turismo moderno, tal y como este autor tuvo ocasión de experimentar por sí mismo durante sus vivencias en las regiones del norte de África.

Turistas, viajeros y visitantes forman la demanda turística y, tras este término, se encuentra un grupo heterogéneo de personas (Figura 1); un agregado de personalidades e intereses con diferentes características sociodemográficas, motivaciones y experiencias. Por ello, son varias las clasificaciones que existen dentro de la demanda turística y todas ellas son de gran interés ya que, a través de la identificación de los modelos de demanda, se busca –además de la ya mencionada homogeneización conceptual que facilite la elaboración de estadísticas– formular adecuadas estrategias de marketing (Organización Mundial del Turismo, 2011).

La OMT (1995), por su parte, distingue entre el concepto amplio de viajero: “cualquier persona que viaje entre dos o más países o entre dos o más localidades de su país de residencia habitual” y el de visitante: “todos los tipos de viajeros relacionados con el turismo” (Figura 2). Otras clasificaciones, como las que sirven de base para las estadísticas elaboradas en España por la Secretaría de Estado de

Comercio, Turismo y de la Pequeña y Mediana Empresa (1993-1996) distinguen entre el turista: “pasajero que permanece una noche por lo menos en un medio de alojamiento colectivo o privado del país visitado” y el excursionista “visitante que no pernocta en un medio de alojamiento colectivo o privado del país visitado”.

### UNIDADES BÁSICAS DEL TURISMO

Todos los viajeros relacionados con el turismo se denominan visitantes. Por consiguiente, el término "visitante" es el concepto básico para el conjunto del sistema de estadísticas de turismo:



A efectos de las estadísticas de turismo y de conformidad con los tipos elementales de turismo, los visitantes pueden clasificarse en:

### VISITANTES INTERNACIONALES

A efectos estadísticos, la expresión "visitante internacional" designa "a toda persona que viaja, por un período no superior a 12 meses, a un país distinto de aquél en el que tiene su residencia habitual, pero fuera de su entorno habitual, y cuyo motivo principal de la visita no es el de ejercer una actividad que se remunere en el país visitado".

Los visitantes internacionales incluyen:



*Un visitante que permanece una noche por lo menos en un medio de alojamiento colectivo o privado en el país visitado.*

*Un visitante que no pernocta en un medio de alojamiento colectivo o privado del país visitado. Esta definición incluye a los pasajeros en crucero, que son las personas que llegan a un país a bordo de un buque de crucero y que vuelven cada noche a bordo de su buque para pernoctar, aunque éste permanezca en el puerto durante varios días. Están comprendidos en este grupo, por extensión, los propietarios o los pasajeros de yates y los pasajeros que participan en un programa de grupo y están alojados en tren.*

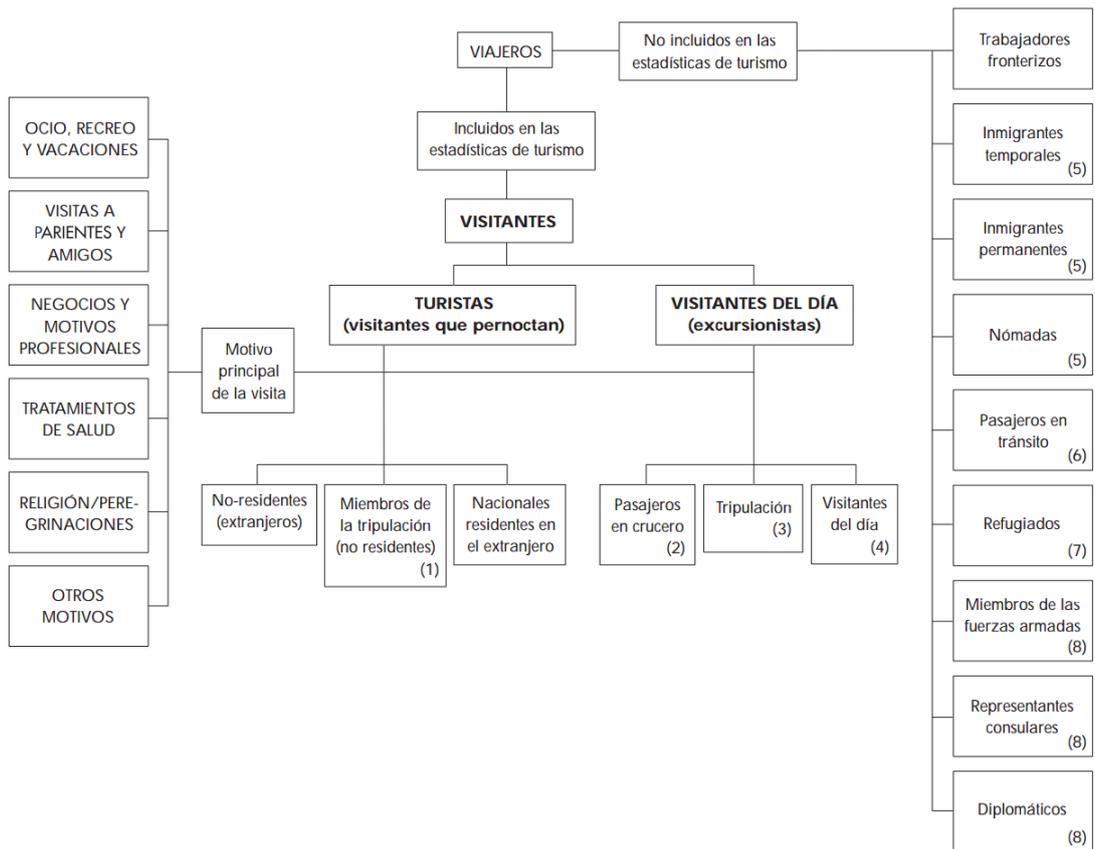
## VISITANTES INTERNOS

A efectos estadísticos, la expresión "visitante interno" designa "a toda persona que reside en un país y que viaja, por una duración no superior a 12 meses, a un lugar dentro del país pero distinto al de su entorno habitual, y cuyo motivo principal de la visita no es el de ejercer una actividad que se remunere en el lugar visitado".



Fuente: Organización Mundial del Turismo (2011)

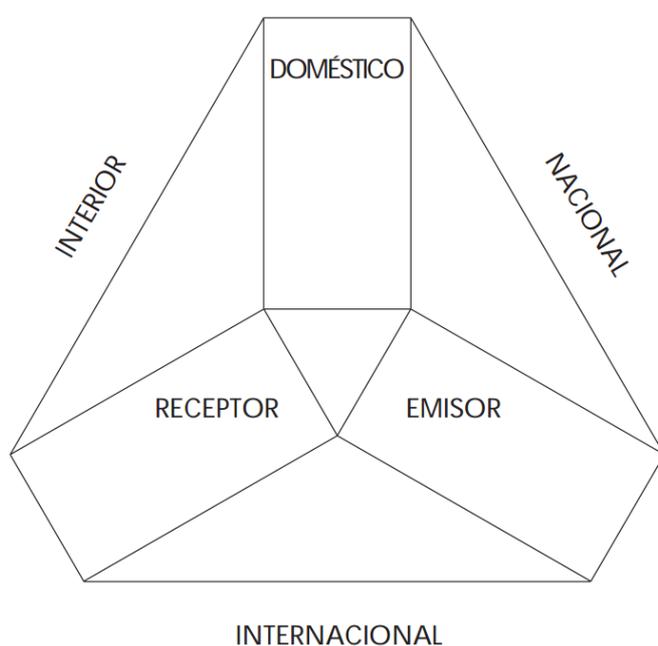
**Figura 1. Unidades básicas del turismo**



Fuente: Organización Mundial del Turismo (2011)

**Figura 2. Clasificación de los visitantes internacionales.**

Aunque la nomenclatura sea distinta, las definiciones de la OMT y de la Secretaría de Estado para el comercio y el turismo coinciden en lo fundamental. Desde el punto de vista de la demanda, atendiendo a cómo se produce la dirección de los flujos o corrientes turísticas, podemos determinar distintas formas de turismo (Figura 3).



Fuente: Organización Mundial del Turismo (2011)

**Figura 3. Formas de turismo, desde el lado de la demanda.**

Así, el lugar de origen de los turistas y el destino elegido por ellos permite distinguir entre: (Organización Mundial del Turismo, 2011)

- Turismo doméstico: residentes visitando su propio país.
- Turismo receptivo: no residentes procedentes de un país determinado.

- Turismo emisor: residentes del propio país se dirigen a otros países.
- Estas tres formas de turismo pueden combinarse en:
- Turismo interior: doméstico y receptivo.
- Turismo nacional: doméstico y emisor.
- Turismo internacional: emisor y receptivo

### **A.3. Factores determinantes de la demanda turística**

La propia complejidad a la hora de definir la demanda turística como concepto global, hace necesario un previo análisis de cómo los distintos factores que condicionan la decisión de viajar influyen sobre la propia estructura de la misma. Estos factores pueden agruparse en cinco grandes grupos: (Organización Mundial del Turismo, 2011)

1. Económicos.
2. Relativos a las unidades demandantes.
3. Aleatorios.
4. Relativos a los sistemas de comercialización.
5. Relativos a la producción.

### **A.4. Impactos económicos del turismo** (Organización Mundial del Turismo, 2011)

El turismo repercute tremendamente en la economía de los países y regiones en los que se desarrolla, aunque su importancia tiene distinta intensidad según sea el dinamismo y la diversificación de dicha economía, es decir, según sea ésta local,

regional o nacional. En efecto, la economía en cuestión puede ser la propia de un país desarrollado o de un país en vías de desarrollo, puede estar basada en varias industrias o en una sola, por lo que el turismo puede representar una opción importante para la misma o ser completamente irrelevante. Estas características determinarán el grado de participación local y de las inversiones extranjeras en el desarrollo de la actividad turística, así como los beneficios y costes que se derivan de la misma.

Los países en vías de desarrollo se caracterizan normalmente por bajos niveles de renta repartida muy desigualmente, altos índices de desempleo, bajo desarrollo industrial frenado fundamentalmente por la escasa demanda nacional de bienes de consumo, una gran dependencia de la agricultura para las exportaciones y alta participación extranjera en la propiedad de empresas manufactureras y de servicios. Por todo ello, la rápida inyección de ingresos que supone el gasto turístico y las inversiones extranjeras tiene en esos países efectos más significativos que en los países desarrollados –generalmente con economías más diversificadas–aportando las divisas necesarias para impulsar el desarrollo económico.

Pero, además, los defensores del desarrollo de la actividad turística argumentan que el turismo no sólo aporta divisas, sino que también alivia los problemas del desempleo y, a largo plazo, puede suministrar un sustituto de las exportaciones tradicionales, cuyo futuro es más inseguro que el del turismo. Efectivamente, se puede considerar al turismo internacional como una actividad de exportación invisible de bienes y servicios turísticos por parte del país receptor de los turistas y

visitantes, con la particularidad de que éstos efectúan el consumo de dichos bienes y servicios en el propio país receptor. Análogamente, el turismo nacional podría considerarse como una exportación, pero entre distintas regiones de un mismo país. Partiendo de estas consideraciones, cabe destacar la gran ventaja que supone la industria turística para un país, en su condición de exportador invisible (receptor de turistas), ya que, entre otras cosas, puede controlar y manipular los precios turísticos con un gran margen de maniobra y, así incentivar las llegadas internacionales e influir en el aumento de los beneficios. Sin embargo, en el caso de la exportación de materias primas derivadas de la agricultura y de la industria, el control sobre los precios es mucho menor y, por tanto, también menor su influencia en los beneficios económicos, ya que están gobernados por las fuerzas de los mercados y sujetos a acuerdos comerciales.

Durante décadas, el turismo ha sido alabado por los beneficios económicos que aporta con su desarrollo, pero, aunque tradicionalmente se ha puesto énfasis en este hecho, hay que reconocer que el desarrollo turístico lleva asociado igualmente una serie de costes para el destino en el que tiene lugar. Resulta pues necesario hacer un análisis más profundo de ambos aspectos del turismo.

## **B. Perceptrón Multicapa**

### **B1. Red Neuronal Artificial**

Las redes neuronales artificiales, comúnmente denominadas "redes neuronales", se ha motivado desde su inicio por el reconocimiento de que el cerebro humano

computa de una manera completamente diferente a la computadora digital convencional. En su forma más general, una red neuronal es una máquina que está diseñada para modelar la forma en que el cerebro realiza una tarea o función particular de interés. Para lograr un buen desempeño, las redes neuronales emplean una interconexión masiva de celdas de computación simples denominadas "neuronas" o "unidades de procesamiento". Por lo tanto, podemos ofrecer la siguiente definición de una red neuronal vista como una máquina adaptativa: Una red neuronal es un procesador distribuido masivamente paralelo formado por unidades de procesamiento simples que tiene una propensión natural a almacenar el conocimiento experiencial y ponerlo a disposición para su uso. Se parece al cerebro en dos aspectos: Primero, el conocimiento es adquirido por la red desde su entorno a través de un proceso de aprendizaje, y segundo las fortalezas de conexión interna, conocidas como pesos sinápticos, se utilizan para almacenar el conocimiento adquirido (Haykin, 2009).

La neurona artificial, célula o autómatas, es un elemento que posee un estado interno, llamado nivel de activación, y recibe señales que le permiten, en su caso cambiar de estado. Las neuronas poseen una función que les permite cambiar de nivel de activación a partir de las señales que reciben; a dicha función se la denomina función de transición de estado o función de activación. Las señales que recibe cada neurona pueden provenir del exterior o de las neuronas a las cuales está conectada. El nivel de activación de una célula depende de las entradas recibidas y de los valores sinápticos, pero no de anteriores valores de estados de activación. Para

calcular el estado de activación se ha de calcular en primer lugar la entrada total a la célula. Este valor se calcula como la suma de todas las entradas ponderadas por ciertos valores (Isasi & Galván, 2004). Así pues, una red neuronal artificial podría definirse como un grafo cuyos nodos están constituidos por unidades de proceso idénticas, y que propagan información a través de los arcos. En este grafo se distinguen tres tipos de nodos: los de entrada, los de salida y los intermedios.

### ***Ventajas que ofrecen la red neuronal*** (Haykin, 2009)

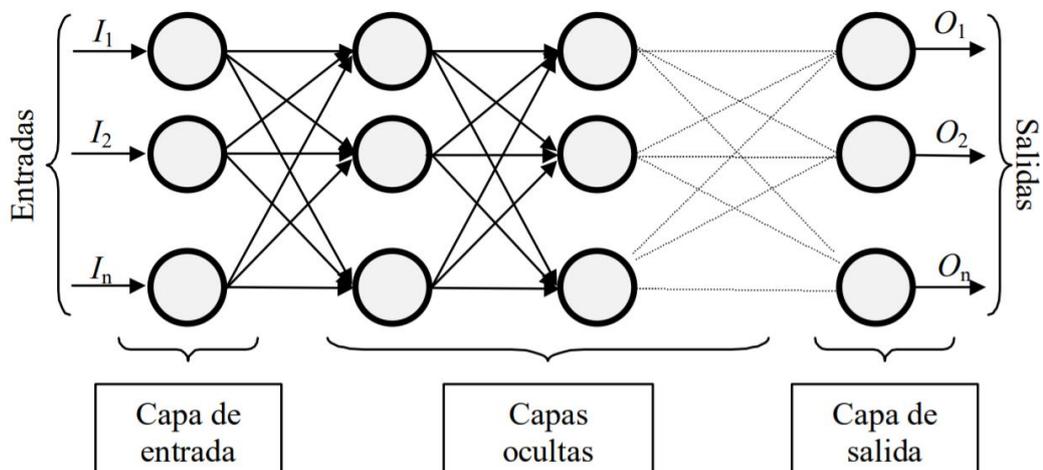
Debido a su constitución y a sus fundamentos, las redes neuronales artificiales presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a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

- **Aprendizaje Adaptativo.** Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.
- **Auto-organización.** Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.

- Tolerancia a fallos. La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.
- Operación en tiempo real. Los cálculos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.
- Fácil inserción dentro de la tecnología existente. Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilitará la integración modular en los sistemas existentes.

***Elementos básicos que componen una red neuronal*** (Gorunescu, 2011)

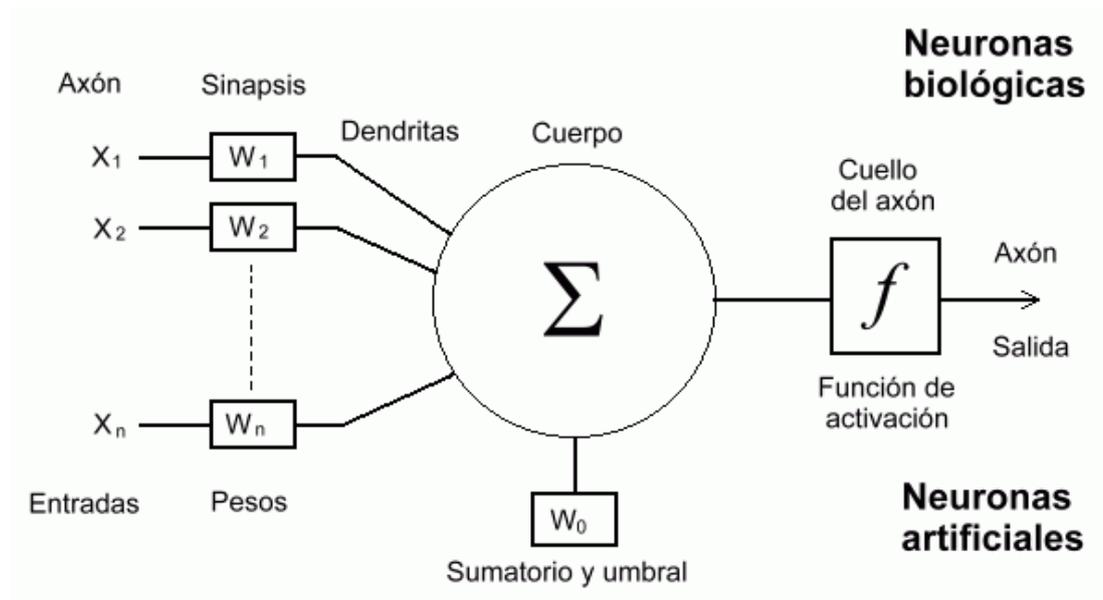
Está constituida por neuronas interconectadas y arregladas en tres capas (esto último puede variar). Los datos ingresan por medio de la “capa de entrada”, pasan a través de la “capa oculta” y salen por la “capa de salida”. Cabe mencionar que la capa oculta puede estar constituida por varias capas.



Fuente: Gorunescu (2011)

**Figura 4. Ejemplo de una red neuronal totalmente conectada.**

Antes de comenzar el estudio sobre las redes neuronales, se debe aprender algo sobre las neuronas y de cómo ellas son utilizadas por una red neuronal. En la Figura 5 se compara una neurona biológica con una neurona artificial. En la misma se pueden observar las similitudes entre ambas (tienen entradas, utilizan pesos y generan salidas).



Fuente: Gorunescu (2011)

**Figura 5. Comparación entre una neurona biológica y una artificial.**

Mientras una neurona es muy pequeña en sí misma, cuando se combinan cientos, miles o millones de ellas pueden resolver problemas muy complejos. Por ejemplo, el cerebro humano se compone de billones de tales neuronas.

***Función de entrada*** (Gorunescu, 2011)

La neurona trata a muchos valores de entrada como si fueran uno solo; esto recibe el nombre de entrada global. Por lo tanto, ahora nos enfrentamos al problema de cómo se pueden combinar estas simples entradas ( $in_{i1}, in_{i2}, \dots$ ) dentro de la entrada global,  $gin_i$ . Esto se logra a través de la función de entrada, la cual se calcula a partir del vector entrada. La función de entrada puede describirse como sigue:

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

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

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

Algunas de las funciones de entrada más comúnmente utilizadas y conocidas son:

- 1) Sumatoria de las entradas pesadas: es la suma de todos los valores de entrada a la neurona, multiplicados por sus correspondientes pesos.

$$\sum_j (n_{ij} w_{ij}), \text{ con } j = 1, 2, 3, \dots, n$$

- 2) Productoria de las entradas pesadas: es el producto de todos los valores de entrada a la neurona, multiplicados por sus correspondientes pesos.

$$\prod_j (n_{ij} w_{ij}), \text{ con } j = 1, 2, 3, \dots, n$$

- 3) Máximo de las entradas pesadas: solamente toma en consideración el valor de entrada más fuerte, previamente multiplicado por su peso correspondiente.

$$\text{Max}_j(n_{ij}w_{ij}), \text{ con } j = 1, 2, 3, \dots, n$$

**Función de activación** (Haykin, 2009).

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

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

La función activación, es una función de la entrada global ( $g_{in_i}$ ) menos el umbral ( $\Theta_i$ ). Las funciones de activación más comúnmente utilizadas se detallan a continuación:

### **1. Función lineal**

Los valores de salida obtenidos por medio de esta función de activación serán:  $a \cdot (g_{in_i} - \Theta_i)$ , cuando el argumento de  $(g_{in_i} - \Theta_i)$  esté comprendido dentro del rango  $(-1/a, 1/a)$ . Por encima o por debajo de esta zona se fija la salida en 1 o -1, respectivamente. Cuando  $a = 1$  (siendo que la misma afecta la pendiente de la gráfica), la salida es igual a la entrada.

$$f(x) = \begin{cases} -1 & x \leq -1/a \\ a * x & -1/a < x < 1/a \\ 1 & x \geq 1/a \end{cases}$$

con  $x = gin_i - \Theta_i$ , y  $a > 0$ .

## 2. Función sigmoidea

Los valores de salida que proporciona esta función están comprendidos dentro de un rango que va de 0 a 1. Al modificar el valor de  $g$  se ve afectada la pendiente de la función de activación.

$$f(x) = \frac{1}{1 + e^{-gx}}, \text{ con } x = gin_i - \Theta_i.$$

## 3. Función tangente hiperbólica

Los valores de salida de la función tangente hiperbólica están comprendidos dentro de un rango que va de -1 a 1. Al modificar el valor de  $g$  se ve afectada la pendiente de la función de activación.

$$f(x) = \frac{e^{gx} - e^{-gx}}{e^{gx} + e^{-gx}}, \text{ con } x = gin_i - \Theta_i.$$

Para explicar porque se utilizan estas funciones de activación se suele emplear la analogía a la aceleración de un automóvil. Cuando un auto inicia su movimiento necesita una potencia elevada para comenzar a acelerar. Pero al ir tomando velocidad, esta demanda un menor incremento de dicha potencia para mantener la aceleración. Al llegar a altas velocidades, nuevamente un amplio incremento en la potencia es necesario para obtener una pequeña ganancia de velocidad. En resumen,

en ambos extremos del rango de aceleración de un automóvil se demanda una mayor potencia para la aceleración que en la mitad de dicho rango.

***Función de salida*** (Isasi & Galván, 2004).

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

Dos de las funciones de salida más comunes son:

Ninguna: este es el tipo de función más sencillo, tal que la salida es la misma que la entrada. Es también llamada función identidad.

Binaria:  $\begin{cases} 1 & \text{si } act_i \geq \xi_i \\ 0 & \text{de lo contrario} \end{cases}$ , donde  $\xi_i$  es el umbral.

## **B2. Perceptron multicapa** (Haykin, 2009)

El Perceptron multicapa es una generalización del Perceptron simple y surgió como consecuencia de las limitaciones de dicha arquitectura en lo referente al problema de la separabilidad no lineal. Minsky y Papert mostraron en 1969 que la combinación de varios Perceptrones simples -inclusión de neuronas ocultas- podía resultar una solución adecuada para tratar ciertos problemas no lineales. Sin

embargo, los autores no presentaron una solución al problema de cómo adaptar los pesos de la capa de entrada a la capa oculta, pues la regla de aprendizaje del Perceptron simple no puede aplicarse en este escenario. No obstante, la idea de combinar varios Perceptrones sirvió de base para estudios posteriores realizados por Rummelhart, Hinton y Wilians en 1986. Estos autores presentaron una manera de retropropagación de los errores medidos en la salida de la red hacia las neuronas ocultas, dando lugar a la llamada regla delta generalizada.

Diferentes autores han demostrado independientemente que el Perceptron multicapa es un aproximador universal, en el sentido de que cualquier función continua en un espacio  $R^n$  puede aproximarse con un Perceptron multicapa, con al menos una capa oculta de neuronas. Este resultado sitúa al Perceptron multicapa como un modelo matemático útil a la hora de aproximar o interpolar relaciones no lineales entre datos de entrada y salida.

Dentro del marco de las redes de neuronas, el perceptron multicapa es en la actualidad una de las arquitecturas más utilizadas en la resolución de problemas. Esto es debido, fundamentalmente, a su capacidad como aproximado universal, así como a su fácil uso y aplicabilidad.

Por otra parte, esto no implica que sea una de las redes más potentes y con mejores resultados en sus diferentes áreas de aplicación. De hecho, el perceptron multicapa posee una serie de limitaciones, como el largo proceso de aprendizaje para problemas complejos dependientes de un gran número de variables; la dificultad para realizar un análisis teórico de la red debido a la presencia de componentes no

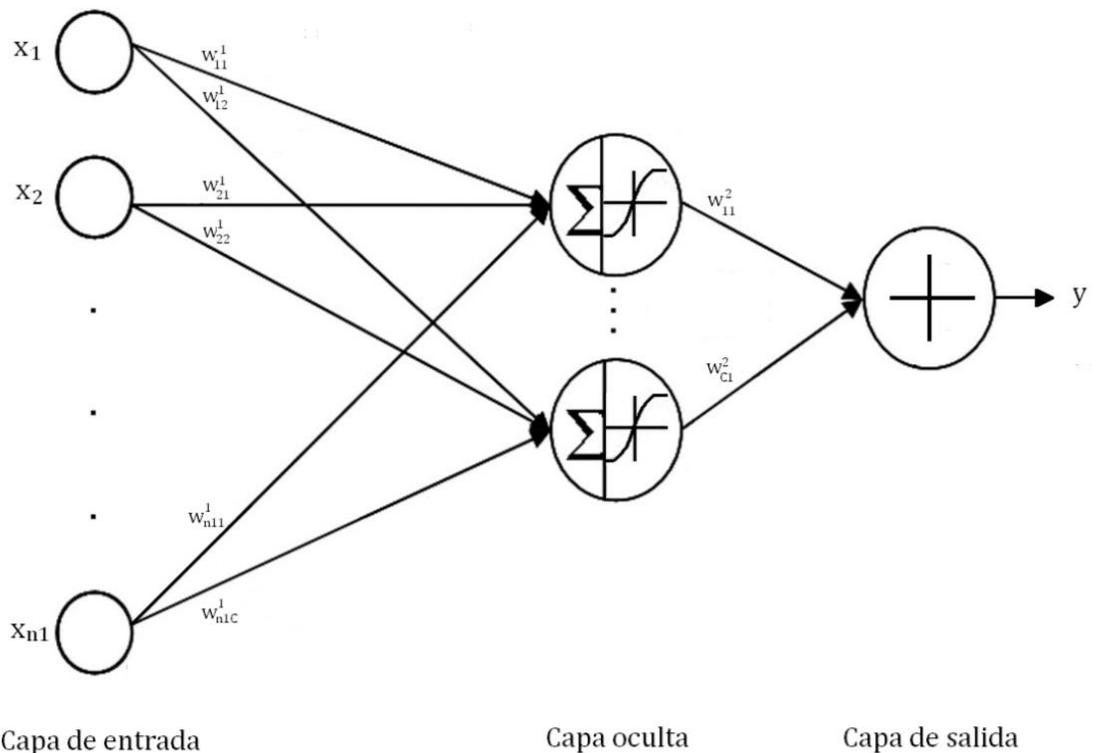
lineales y a la alta conectividad. Por otra parte, es necesario señalar que el proceso de aprendizaje de la red busca en un espacio amplio de funciones, una posible función que relacione las variables de entrada y salida al problema, lo cual puede complicar su aprendizaje y reducir su efectividad en determinadas aplicaciones.

***Arquitectura del perceptron multicapa*** (Isasi & Galván, 2004)

La arquitectura de Perceptron multicapa se caracteriza porque tiene sus neuronas agrupadas en capas de diferentes niveles. Cada una de las capas está formada por un conjunto de neuronas y se distinguen tres tipos de capas diferentes: la capa de entrada, las capas ocultas y la capa de salida. Las neuronas de la capa de entrada no actúan como neuronas propiamente dichas, sino que se encargan únicamente de recibir las señales o patrones del exterior y propagar dichas señales a todas las neuronas de la siguiente capa. La última capa actúa como salida de la red, proporcionando al exterior la respuesta de la red para cada uno de los patrones de entrada. Las neuronas de las capas ocultas realizan un procesamiento no lineal de los patrones recibidos. Como se observa en la figura 6, las conexiones del Perceptron multicapa siempre están dirigidas hacia adelante, es decir, las neuronas de una capa se conectan con las neuronas de la siguiente capa, de ahí que reciban también el nombre de redes alimentadas hacia adelante o “feedforward”. Las conexiones entre las neuronas de la red llevan también asociado un umbral, que el caso del Perceptron multicapa suele tratarse como una conexión más a la neurona, cuya entrada es constante e igual a 1. Generalmente, todas las neuronas de una capa

están conectadas a todas las neuronas de la siguiente capa. Se dice entonces que existe conectividad total o que la red está totalmente conectada. Aunque en la mayor parte de los casos la arquitectura del Perceptron multicapa está asociada al esquema de la figura 6, es posible también englobar dentro de este tipo de redes a arquitecturas con las siguientes características:

- Redes con conexiones de todas o ciertas neuronas de una determinada capa a neuronas de capas posteriores, aunque no inmediatamente posteriores.
- Redes en las que ciertas neuronas de ciertas capas no están conectadas a neuronas de la siguiente capa, es decir, el peso de la conexión es constante e igual a cero



Fuente: Isasi & Galván (2004)

**Figura 6. Perceptron de tres capas con una capa oculta**

Cuando se aborda un problema con el Perceptron multicapa, en la mayoría de los casos se parte de una arquitectura totalmente conectada, es decir, todas las neuronas de una capa están conectadas a todas las neuronas de la siguiente capa. No es posible demostrar que, si se utilizan arquitecturas en las que se eliminan o se añaden conexiones de una capa a capas no inmediatamente posteriores, se puedan obtener mejores resultados. Sin embargo, en ocasiones, y debido fundamentalmente a la naturaleza del problema, se pueden encontrar redes multicapa con estas características en sus conexiones

***Propagación de los patrones de entrada*** (Isasi & Galván, 2004)

El Perceptrón multicapa define una relación entre las variables de entrada y las variables de salida de la red. Esta relación se obtiene propagando hacia adelante los valores de las variables de entrada. Para ello, cada neurona de la red procesa la información recibida por sus entradas y produce una respuesta o activación que se propaga, a través de las conexiones correspondientes, hacia las neuronas de la siguiente capa. A continuación, se muestran las expresiones para calcular las activaciones de las neuronas de la red.

Sea un Perceptron multicapa con  $C$  capas “ $C - 2$  capas ocultas” y  $n_c$  neuronas en la capa  $c$ , para  $c = 1, 2, \dots, C$ . Sea  $W^c = (w_{ij}^c)$  la matriz de pesos donde  $w_{ij}^c$  representa el peso de la conexión de la neurona  $i$  de la capa  $c$  para  $c = 2, \dots, C$ . Denotaremos  $a_i^c$  a la activación de la neurona  $i$  de la capa  $c$ . Estas activaciones se calculan del siguiente modo:

- Activación de las neuronas de la capa de entrada ( $a^1_i$ ). Las neuronas de la capa de entrada se encargan de transmitir hacia la red las señales recibidas desde el exterior. Por tanto:  $a^1_i = x_i$  para  $i = 1, 2, \dots, n_1$   
donde  $X = (x_1, x_2, \dots, x_{n_1})$  representa el vector o patrón de entrada a la red.
- Activación de las neuronas de la capa oculta  $c$  ( $a^c_i$ ). Las neuronas ocultas de la red procesan la información recibida aplicando la función de activación “f” a la suma de los productos de las activaciones que recibe por sus correspondientes pesos, es decir:

$$a^c_i = f \left( \sum_{j=1}^{n_{c-1}} w_{ji}^{c-1} a_j^{c-1} + u_i^c \right) \text{ para } i = 1, 2, \dots, n_c \text{ y } c = 2, 3, \dots, C - 1$$

donde  $a_j^{c-1}$  son las activaciones de las neuronas de la capa  $c - 1$ .

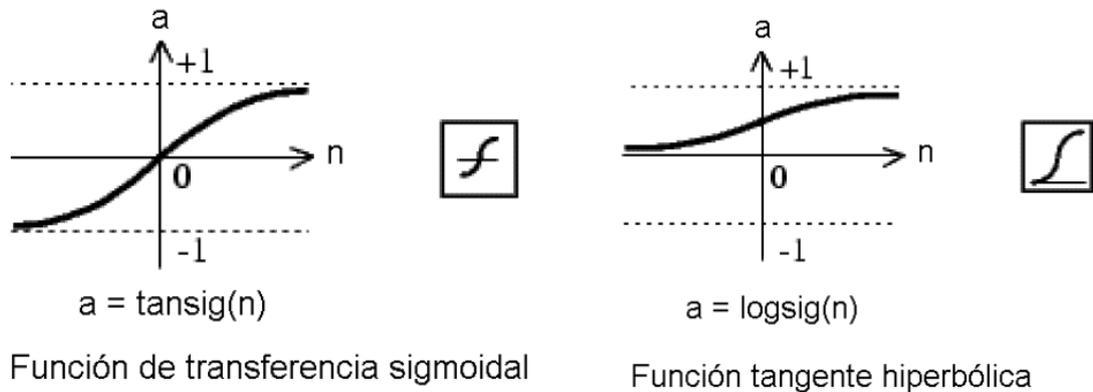
- Activación de las neuronas de la capa de salida ( $a^C_i$ ). Al igual que en el caso anterior, la activación de estas neuronas viene dada por la función de activación “f” aplicada a la suma de los productos de las entradas que recibe por sus correspondientes pesos:

$$y_i = a^C_i = f \left( \sum_{j=1}^{n_{C-1}} w_{ji}^{C-1} a_j^{C-1} + u_i^C \right) \text{ para } i = 1, 2, \dots, n_c$$

donde  $Y = (y_1, y_2, \dots, y_{n_c})$  es el vector de salida de la red.

La función “f” es la llamada función de activación. Para el Perceptron multicapa, las funciones de activación más utilizadas son la función sigmoideal y la función tangente hiperbólica. Dichas funciones poseen como imagen un intervalo continuo

de valores dentro de los intervalos  $[0, 1]$  y  $[-1, 1]$ , respectivamente, y vienen dadas por las siguientes ecuaciones:



Fuente: Isasi & Galván (2004)

**Figura 7. Funciones de activación sigmoideal y tangente hiperbólica.**

Función sigmoideal:

$$f_{sigm}(x) = \frac{1}{1 + e^{-x}}$$

Función tangente hiperbólica:

$$f_{thip}(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$$

Ambas son funciones crecientes con dos niveles de saturación: el máximo, que proporciona salida 1, y el mínimo, salida 0 para la función sigmoideal y salida -1, para la tangente hiperbólica, como se observa en la figura 7.

En algunas ocasiones, la función de activación en el Perceptron multicapa es común a todas las neuronas de la red y es elegida por el diseñador, elección que se realiza únicamente basándose en los valores de activación que se desee que alcancen las

neuronas. Ambas funciones están relacionadas mediante la expresión  $f_{\text{thip}}(x) = 2f_{\text{sigm}}(x) - 1$ , por lo que la utilización de una u otra se elige únicamente en función del recorrido que interese.

En otras ocasiones, y dependiendo de la naturaleza del problema, las neuronas de salida se distinguen del resto de neuronas de la red, utilizando otro tipo de función de activación. En este caso, las más usadas son la función identidad y la función escalón. De las ecuaciones anteriores, se observa que el perceptron multicapa define, a través de sus conexiones y neuronas, una función continua no lineal del espacio  $R^{n^I}$  -espacio de los patrones de entrada- al espacio  $R^{n^C}$  -espacio de los patrones de salida-. Se puede escribir, por tanto, que:

$$Y = F(X, W)$$

donde  $Y$  es el vector formado por las salidas de la red,  $X$  es el vector de entrada a la red,  $W$  es el conjunto de todos los parámetros de la red -pesos y umbrales- y  $F$  es una función continua no lineal dada por las ecuaciones anteriores.

### ***Consideraciones de diseño*** (Isasi & Galván, 2004)

Cuando se aborda un problema utilizando el Perceptron multicapa, uno de los primeros pasos a realizar es el diseño de la arquitectura de la red. Este diseño implica la determinación de la función de activación a emplear, el número de neuronas y el número de capas de la red.

Como se ha comentado anteriormente, la elección de la función de activación se suele hacer basándose en el recorrido deseado, y el hecho de elegir una u otra, generalmente, no influye en la capacidad de la red para resolver el problema.

En lo que respecta al número de neuronas y capas, algunos de estos parámetros vienen dados por el problema y otros deben ser elegidos por el diseñador. Así, por ejemplo, tanto el número de neuronas en la capa de entrada, como el número de neuronas en la capa de salida, vienen dados por las variables que definen el problema. En algunas aplicaciones prácticas, no hay lugar a duda sobre el número de entradas y salidas. Sin embargo, existen problemas los que el número de variables de entrada relevantes para el problema no se conoce con exactitud. En estos casos, se disponen de un gran número de variables, algunas de las cuales podrían no aportar información relevante a la red, y su utilización podría complicar el aprendizaje, pues implicaría arquitecturas de gran tamaño y con alta conectividad. En estas situaciones, es conveniente realizar un análisis previo de las variables de entrada más relevantes al problema y descartar aquellas que no aportan información a la red. Este análisis puede llegar a ser una tarea complicada y requerir técnicas avanzadas, como técnicas basadas en análisis de correlación, análisis de componentes principales, análisis de importancia relativa, análisis de sensibilidad o técnicas basadas en algoritmos genéticos, entre otras.

El número de capas ocultas y el número de neuronas en estas capas deben ser elegidos por el diseñador. No existe un método o regla que determine el número óptimo de neuronas ocultas para resolver un problema dado. En la mayor parte de

las aplicaciones prácticas, estos parámetros se determinan por prueba y error. Partiendo de una arquitectura ya entrenada, se realizan cambios aumentando o disminuyendo el número de neuronas ocultas y el número de capas hasta conseguir una arquitectura adecuada para el problema a resolver, que pudiera no ser la óptima, pero que proporciona una solución.

Si bien el número de neuronas ocultas puede influir en el comportamiento de la red, como se verá más adelante -capacidad de generalización de la red-, es necesario indicar que en el caso del Perceptron multicapa, generalmente, el número de neuronas ocultas no es parámetro significativo, pues dado un problema, pueden existir una gran cantidad de arquitecturas capaces de resolver de manera adecuada dicho problema. Además, añadir o eliminar una neurona o culta no influye, de manera significativa, en la capacidad predictiva de la red.

En la actualidad existen líneas de investigación abiertas centradas en la determinación automática del número de neuronas o cultas, así como de capas o cultas, para cada problema en particular. En el caso del Perceptron multicapa, la mayor parte de estos trabajos se basan en la utilización de técnicas evolutivas, las cuales realizan una búsqueda en el espacio de las arquitecturas de redes guiada por la optimización del rendimiento de la red.

#### ***Algoritmo de Retropropagación*** (Haykin, 2009)

La regla o algoritmo de aprendizaje es el mecanismo mediante el cual se van adaptando y modificando todos los parámetros de la red. En el caso del perceptron

multicapa se trata de un algoritmo de aprendizaje supervisado, es decir, la modificación de los parámetros se realiza para que la salida de la red sea lo más próxima posible a la salida proporcionada por el supervisor o salida deseada.

Por tanto, para cada patrón de entrada a la red es necesario disponer de un patrón de salida deseada.

Puesto que el objetivo es que la salida de la red sea lo más próxima posible a la salida deseada, el aprendizaje de la red se formula como un problema de minimización del siguiente modo:

$$\text{Min}_w E$$

siendo  $W$  el conjunto de parámetros de la red -pesos y umbrales- y  $E$  una función error que evalúa la diferencia entre las salidas de la red y las salidas deseadas. En la mayor parte de los casos, la función error se define como:

$$E = \frac{1}{N} \sum_{n=1}^N e(n)$$

donde  $N$  es el número de patrones o muestras y  $e(n)$  es el error cometido por la red para el patrón  $n$ , dado por:

$$e(n) = \frac{1}{n_C} \sum_{i=1}^{n_C} (s_i(n) - y_i(n))^2$$

siendo  $Y(n) = (y_1(n), \dots, y_{n_C}(n))$  y  $S(n) = (s_1(n), \dots, s_{n_C}(n))$  los vectores de salidas de la red y salidas deseadas para el patrón  $n$ , respectivamente.

De este modo, si  $W^*$  es un mínimo de la función error  $E$ , en dicho punto el error es próximo a cero, lo cual implica que la salida de la red es próxima a la salida deseada, alcanzando así la meta de la regla de aprendizaje.

Por tanto, el aprendizaje del Perceptron multicapa es equivalente a encontrar un mínimo de la función error. La presencia de funciones de activación no lineales hace que la respuesta de la red sea no lineal respecto a los parámetros ajustables, por lo que el problema de minimización es un problema no lineal, y, como consecuencia, tienen que utilizarse técnicas de optimización no lineales para su resolución. Dichas técnicas están, generalmente, basadas en una adaptación de los parámetros siguiendo una cierta dirección de búsqueda. En el contexto de redes de neuronas, y en particular para el perceptron multicapa, la dirección de búsqueda más comúnmente usada es la dirección negativa del gradiente de la función  $E$  - método de descenso del gradiente-, pues conforme al cálculo de varias variables, ésta es la dirección en la que la función decrece.

Aunque, estrictamente hablando, el aprendizaje de la red debe realizarse para minimizar el error total, el procedimiento más utilizado está basado en métodos del gradiente estocástico, los cuales consisten en una sucesiva minimización de los errores para cada patrón,  $e(n)$ , en lugar de minimizar el error total  $E$ . Por tanto, aplicando el método de descenso del gradiente estocástico, cada parámetro  $w$  de la red se modifica para cada patrón de entrada  $n$  de acuerdo con la siguiente ley de aprendizaje.

$$w(n) = w(n - 1) - \alpha \frac{\partial e(n)}{\partial w}$$

donde  $e(n)$  es el error para el patrón  $n$  dado por la ecuación, y  $\alpha$  es la razón o tasa de aprendizaje, parámetro que influye en la magnitud del desplazamiento en la superficie del error, como se analizará más adelante.

Debido a que las neuronas de la red están agrupadas en capas de distintos niveles, es posible aplicar el método del gradiente de forma eficiente, resultando el conocido algoritmo de retropropagación o regla delta generalizada. El término de retropropagación se utiliza debido a la forma de implementar el método del gradiente en el perceptrón multicapa, pues el error cometido en la salida de la red es propagado hacia atrás, transformándolo en un error para cada una de las neuronas ocultas de la red.

### 2.2.2. Definición de términos

- **Parámetro:** Medida de resumen de una población (Gutiérrez, 2012)
- **Normalización:** La normalización de los datos intenta dar a todos los atributos un peso igual (Han, Kamber, & Pei, 2012).
- **Neurona:** Una neurona es una unidad de procesamiento de información que es fundamental para el funcionamiento de una red neuronal (Haykin, 2009).
- **Aprendizaje supervisado:** Los datos del conjunto de aprendizaje tienen dos tipos de atributos: los datos propiamente dichos y cierta información relativa a la solución del problema (Isasi & Galván, 2004).

- **Aprendizaje no supervisado:** Los datos del conjunto de aprendizaje sólo tienen información de los ejemplos, y no hay nada que permita guiar en el proceso de aprendizaje (Isasi & Galván, 2004).
- **Turismo receptivo:** El turismo receptivo es el que se produce en un país, cuando llegan a él visitantes que residen en otras naciones con la intención de permanecer un tiempo limitado en el mismo, para luego viajar a otros países o regresar al lugar de origen. La permanencia debe ser igual o superior a las 24 horas y la finalidad del viaje, incluso, acepta que sea por razones comerciales, de estudio, de salud, o de trabajo, siempre y cuando, en este último caso, el empleo sea temporal como los del tipo de asesoría internacional, muy frecuente en las empresas o grupos económicos que utilizan tecnología extranjera. También hace referencia a los viajeros que temporalmente, y por diferentes motivos, llegan a un país proveniente del país de domicilio habitual (Ibáñez & Cabrera, 2011).
- **Turismo interno:** Se entiende por turismo interno el uso y consumo de servicios turísticos, realizado por los residentes nacionales o extranjeros en un país, fuera de su domicilio habitual, pero dentro del territorio nacional por un plazo mayor de 24 horas, pero menor de 90 días (Ibáñez & Cabrera, 2011).
- **Error absoluto medio porcentual** (Villada, Muñoz, & García-Quintero, 2016):  $MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{y'_t - y_t}{y_t} \right|$

**CAPÍTULO III: HIPÓTESIS Y  
OPERACIONALIZACIÓN DE VARIABLES**

### 3.1. Hipótesis

La capacidad predictiva del perceptrón multicapa de una red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018 es inferior al 5% del error absoluto medio porcentual.

### 3.2. Operacionalización de variables

Las variables de la presente investigación son:

<i>Variable</i>	<i>Indicadores</i>	<i>Tipo de variables</i>
Variable independiente: Número de turistas de enero 2003 a diciembre 2017	a. Número de turistas internacionales	Cuantitativo
	b. Número de turistas nacionales	Cuantitativo
	c. Número total de turistas (a+b)	Cuantitativo
Variable dependiente Número de turistas de enero 2018 a diciembre 2018	a. Número de turistas internacionales	Cuantitativo
	b. Número de turistas nacionales	Cuantitativo
	c. Número total de turistas (a+b)	Cuantitativo

## **CAPÍTULO IV: METODOLOGÍA**

## **4.1. Materiales y lugar de ejecución**

### **4.1.1. Lugar**

Instituto Nacional de Estadística e Informática.

### **4.1.2. Materiales**

Los materiales utilizados para el presente trabajo de tesis fueron los útiles de escritorio como papel bond, lapiceros, cuadernos de apunte, USB.

### **4.1.3. Equipos**

Los equipos utilizados en el presente trabajo de tesis fueron una laptop, una impresora, fotocopidora.

### **4.1.4. Recurso humano**

El presente trabajo de tesis contó con la asesoría de un docente de la escuela académico profesional de Estadística e Informática y dos investigadores quienes son los autores de la presente tesis.

## **4.2. Métodos**

### **4.2.1. Técnicas de recolección de datos**

Para la presente investigación se recopilará información del sistema de base de datos del INEI (<http://inei.inei.gob.pe/microdatos/>), de la serie temporal del turismo al departamento de Ancash.

#### **4.2.2. Tipo de estudio**

La presente tesis fue longitudinal, ya que se recabaron los datos en diferentes puntos del tiempo, para la realización inferencias acerca de la evolución, y de tipo de diseño de tendencia ya que se analizaron los cambios a través del tiempo dentro de la población estudiada. (Hernández, Fernández, & Baptista, 2010).

#### **4.2.3. Diseño de la investigación**

La presente investigación fue de diseño no experimental, ya que se realizó sin la manipulación deliberada de variables y en los que sólo se observaron los fenómenos en su ambiente natural para después analizarlos. (Hernández, Fernández, & Baptista, 2010).

#### **4.2.3. Población y muestra**

**4.2.3.1. Población:** Está constituida por la afluencia turística (nacionales e internacionales) al departamento de Ancash.

**4.2.3.2. Muestra:** Está constituida por la afluencia turística (nacionales e internacionales) de enero del 2003 hasta diciembre de 2017.

#### **4.2.4. Instrumentos de recopilación de datos**

- Técnica:

- Documentaria: Se recopilaron a partir de los registros de arribos a los establecimientos de hospedaje, que se encuentran en las bases de datos del INEI.

- Instrumento:

- Ficha de registro de arribos a los establecimientos de hospedaje.

#### **4.2.5. Análisis Estadístico e interpretación de la información**

Para el procesamiento y organización de los datos se utilizó el software R Project.

El análisis e interpretación estadística de los datos para la presente investigación se realizó por medio de la media aritmética y desviación estándar, presentados en gráficos secuenciales y organizados en las tablas estadísticas. Además, se hizo uso del análisis de redes neuronales artificiales del modelo de perceptrón multicapa.

# **CAPÍTULO V: ANÁLISIS Y DISCUSIÓN DE RESULTADOS**

## 5.1. Análisis de los datos

### *Datos descriptivos de la serie*

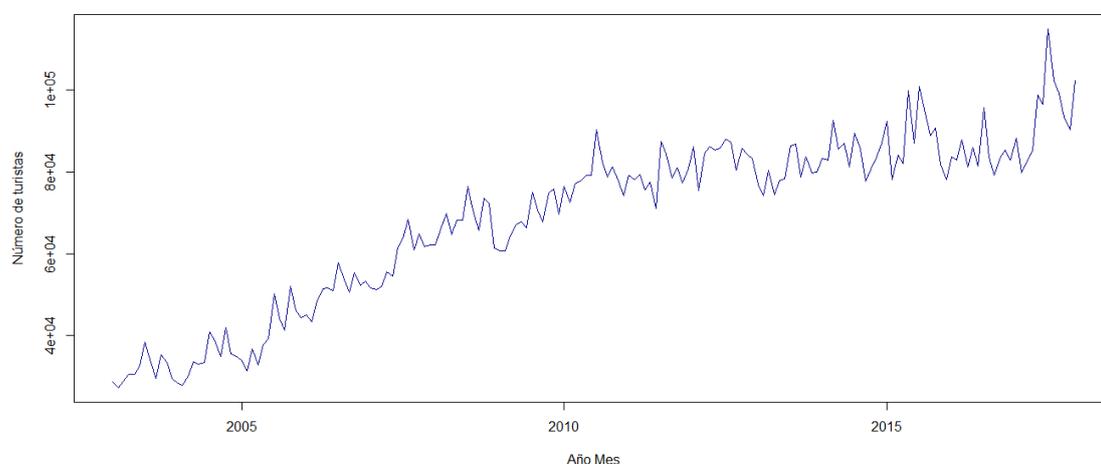
El turismo en el departamento de Ancash se contabilizó de acuerdo a los arribos a los establecimientos de hospedaje del departamento de Ancash, que se encuentran dentro del periodo 2003 al 2017.

Tabla 1

### *Arribos de turistas al departamento de Ancash, 2003 – 2017*

Mes	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
<b>Enero</b>	28732	28443	33863	44975	51743	62242	60775	76444	79131	86063	76850	83318	92380	83661	88099
<b>Febrero</b>	27366	27994	31330	43292	51317	65896	60706	72451	78166	75440	74123	82773	77985	82807	79700
<b>Marzo</b>	28999	30221	36884	48360	52086	69872	64430	77033	79224	84540	80314	92546	84144	87820	82447
<b>Abril</b>	30507	33646	32770	51473	55557	64692	67198	77574	75637	86161	74455	85420	81922	81111	85146
<b>Mayo</b>	30500	32983	37776	51710	54469	68083	67790	79000	77554	85279	77868	86929	99713	85908	98689
<b>Junio</b>	32575	33576	39240	50974	61599	68230	66341	79037	71154	85718	78247	81196	86857	81410	96422
<b>Julio</b>	38513	40846	50211	57886	63858	76347	74947	90274	87427	87877	86345	89489	100682	95595	114780
<b>Agosto</b>	33403	38946	44201	53786	68266	70635	70628	82375	84349	87128	86779	85479	95225	83513	102228
<b>Setiembre</b>	29467	34830	41430	50603	61019	65707	67745	78710	78462	80347	78612	77739	88824	79109	99113
<b>Octubre</b>	35249	42013	52100	55292	64920	73463	74749	81205	81025	85787	83649	80582	90669	83510	93258
<b>Noviembre</b>	33484	35486	46214	52325	61726	72258	75782	77598	77154	84198	79775	83620	81844	85321	90345
<b>Diciembre</b>	29576	34947	44326	53198	62195	61365	69707	74211	80759	83191	80009	86847	78003	82880	102282

De acuerdo a los datos de la tabla 1 y la figura 1, se observa que la serie del turismo al departamento de Ancash, presenta una tendencia creciente con una tasa de crecimiento promedio anual del 8.5%, así como una ligera estacionalidad repitente en el mes de julio con la más alta presencia de turistas en el departamento de Ancash y la más baja presencia de turistas en el mes de febrero, con una diferencia promedio anual del 24% que favorece en el mes de julio respecto al mes de febrero.



*Figura 1.* Arribos de turistas al departamento de Ancash, 2003 – 2017

### ***Perceptrón multicapa de una red neuronal artificial***

La arquitectura comprende un aprendizaje supervisado con corrección del error, de diseño de red multicapa con una o varias capas ocultas, con algoritmo de retropropagación como forma de fluidez de los datos de la serie de tiempo.

Con un umbral de detención de 0.01, con función de activación logístico, teniendo como muestra de aprendizaje del periodo 1 al periodo 132 y la muestra de evaluación comprendida entre los periodos 133 al periodo 168.

La arquitectura comprende el modelo en función a los 12 rezagos anteriores al tiempo “t+1”.

Tabla 2

*Arquitectura con una capa oculta de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arqui- tectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A1	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	1	0.01	Logístico	0.119840	0.009694254	587
A2	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	2	0.01	Logístico	0.120673	0.009388804	422
A3	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	3	0.01	Logístico	0.114894	0.009083891	246
A4	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	4	0.01	Logístico	0.110825	0.009100828	362
A5	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	5	0.01	Logístico	0.114734	0.007910784	258
A6	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	6	0.01	Logístico	0.106504	<b>0.004388368</b>	432
A7	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	7	0.01	Logístico	0.109532	0.007962588	636
A8	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	8	0.01	Logístico	0.111462	0.008120832	410
A9	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	9	0.01	Logístico	0.110733	0.008761562	233
A10	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	10	0.01	Logístico	0.103745	0.009699198	438
A11	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	11	0.01	Logístico	<b>0.101628</b>	0.007508434	616
A12	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	1	12	0.01	Logístico	0.108765	0.008952193	431

Tabla 3

*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A13	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 1	0.01	Logístico	2.620489	<b>0.000778951</b>	37
A14	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 1	0.01	Logístico	0.103937	0.009401002	468
A15	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 1	0.01	Logístico	0.115219	0.009282035	244
A16	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 1	0.01	Logístico	0.100270	0.009518612	731
A17	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 1	0.01	Logístico	0.120480	0.008719583	457
A18	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 1	0.01	Logístico	0.094188	0.008565124	593
A19	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 1	0.01	Logístico	0.119019	0.009801646	214
A20	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 1	0.01	Logístico	0.109428	0.009683461	309
A21	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 1	0.01	Logístico	<b>0.091085</b>	0.008394336	661
A22	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 1	0.01	Logístico	0.098042	0.008857169	407
A23	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 1	0.01	Logístico	2.619960	0.004806691	8
A24	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 1	0.01	Logístico	0.102237	0.009627825	477

Tabla 4

*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A25	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 2	0.01	Logístico	2.620146	<b>0.003257463</b>	42
A26	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 2	0.01	Logístico	0.143048	0.009262101	208
A27	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 2	0.01	Logístico	0.125510	0.008787690	211
A28	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 2	0.01	Logístico	0.136201	0.009787268	186
A29	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 2	0.01	Logístico	0.135861	0.009721190	212
A30	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 2	0.01	Logístico	0.112150	0.008639743	248
A31	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 2	0.01	Logístico	0.123159	0.009517104	322
A32	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 2	0.01	Logístico	<b>0.106592</b>	0.009819027	680
A33	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 2	0.01	Logístico	0.112473	0.008978731	246
A34	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 2	0.01	Logístico	0.110771	0.009620686	570
A35	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 2	0.01	Logístico	0.111684	0.009863894	334
A36	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 2	0.01	Logístico	0.124328	0.007755602	93

Tabla 5

*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A37	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 3	0.01	Logístico	0.122766	0.009315262	759
A38	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 3	0.01	Logístico	0.125922	0.009665187	201
A39	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 3	0.01	Logístico	0.135080	0.008535278	156
A40	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 3	0.01	Logístico	0.109076	0.009905036	235
A41	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 3	0.01	Logístico	0.118606	0.008896680	367
A42	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 3	0.01	Logístico	0.128816	0.009483899	208
A43	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 3	0.01	Logístico	0.114744	0.006848638	251
A44	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 3	0.01	Logístico	0.119200	0.009734553	256
A45	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 3	0.01	Logístico	0.124555	0.008623830	259
A46	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 3	0.01	Logístico	<b>0.107848</b>	<b>0.005200600</b>	174
A47	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 3	0.01	Logístico	0.109012	0.009110224	292
A48	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 3	0.01	Logístico	0.124193	0.009508648	156

Tabla 6

*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A49	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 4	0.01	Logístico	0.117205	0.009352646	393
A50	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 4	0.01	Logístico	0.135461	0.006343879	211
A51	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 4	0.01	Logístico	0.118249	0.009360691	527
A52	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 4	0.01	Logístico	0.133698	0.009970430	211
A53	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 4	0.01	Logístico	0.114403	0.008968199	224
A54	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 4	0.01	Logístico	0.113723	0.009692713	380
A55	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 4	0.01	Logístico	0.121765	<b>0.005867380</b>	198
A56	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 4	0.01	Logístico	0.117936	0.009357945	269
A57	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 4	0.01	Logístico	0.117096	0.008902689	349
A58	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 4	0.01	Logístico	0.106300	0.007824342	471
A59	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 4	0.01	Logístico	<b>0.102124</b>	0.009584443	292
A60	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 4	0.01	Logístico	0.132944	0.006522359	90

Tabla 7

*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A61	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 5	0.01	Logístico	0.128711	0.009421671	392
A62	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 5	0.01	Logístico	0.125246	0.007736087	125
A63	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 5	0.01	Logístico	0.127934	0.007726218	255
A64	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 5	0.01	Logístico	0.115119	0.008897662	310
A65	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 5	0.01	Logístico	0.120426	0.008664580	224
A66	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 5	0.01	Logístico	0.115527	<b>0.007006894</b>	295
A67	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 5	0.01	Logístico	0.116074	0.009097980	198
A68	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 5	0.01	Logístico	0.108050	0.009618591	509
A69	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 5	0.01	Logístico	0.129789	0.007284416	135
A70	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 5	0.01	Logístico	<b>0.106140</b>	0.009118427	254
A71	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 5	0.01	Logístico	0.119144	0.009766466	300
A72	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 5	0.01	Logístico	0.137463	0.008828160	171

Tabla 8

*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A73	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 6	0.01	Logístico	0.121805	0.007478486	466
A74	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 6	0.01	Logístico	0.124712	0.007557024	420
A75	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 6	0.01	Logístico	0.118986	0.008224512	393
A76	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 6	0.01	Logístico	0.113275	0.009211187	363
A77	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 6	0.01	Logístico	0.120790	0.008860397	178
A78	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 6	0.01	Logístico	<b>0.106020</b>	0.008080884	520
A79	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 6	0.01	Logístico	0.109887	0.008770700	492
A80	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 6	0.01	Logístico	0.112285	0.007770511	185
A81	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 6	0.01	Logístico	0.119694	<b>0.003968495</b>	116
A82	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 6	0.01	Logístico	0.116483	0.009893875	190
A83	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 6	0.01	Logístico	0.118539	0.009630511	217
A84	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 6	0.01	Logístico	0.107899	0.007378000	201

Tabla 9

*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A85	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 7	0.01	Logístico	2.622359	<b>0.002420552</b>	41
A86	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 7	0.01	Logístico	0.130691	0.008167497	299
A87	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 7	0.01	Logístico	0.136314	0.009396734	112
A88	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 7	0.01	Logístico	0.123004	0.009078393	168
A89	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 7	0.01	Logístico	0.128005	0.005306214	94
A90	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 7	0.01	Logístico	0.114131	0.009788193	296
A91	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 7	0.01	Logístico	0.115813	0.007365520	237
A92	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 7	0.01	Logístico	<b>0.107549</b>	0.004635125	386
A93	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 7	0.01	Logístico	0.124380	0.009235173	120
A94	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 7	0.01	Logístico	0.119941	0.009576304	188
A95	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 7	0.01	Logístico	0.107747	0.009815896	222
A96	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 7	0.01	Logístico	0.123128	0.006377438	122

Tabla 10

*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A97	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 8	0.01	Logístico	2.622357	0.009632271	42
A98	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 8	0.01	Logístico	0.122060	0.009790756	611
A99	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 8	0.01	Logístico	0.125567	0.008714462	237
A100	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 8	0.01	Logístico	0.118934	<b>0.006648832</b>	221
A101	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 8	0.01	Logístico	0.123832	0.009839537	295
A102	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 8	0.01	Logístico	0.112874	0.007912826	329
A103	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 8	0.01	Logístico	0.118559	0.009977736	154
A104	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 8	0.01	Logístico	<b>0.112292</b>	0.009515421	318
A105	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 8	0.01	Logístico	0.140248	0.007828391	101
A106	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 8	0.01	Logístico	0.125290	0.008984577	130
A107	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 8	0.01	Logístico	0.114574	0.009775601	318
A108	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 8	0.01	Logístico	0.113231	0.008908111	198

Tabla 11

*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A109	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 9	0.01	Logístico	0.120819	0.008031538	331
A110	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 9	0.01	Logístico	0.118478	0.008812679	240
A111	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 9	0.01	Logístico	0.118376	0.008464659	254
A112	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 9	0.01	Logístico	0.115125	0.009563943	362
A113	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 9	0.01	Logístico	0.120616	0.009630951	266
A114	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 9	0.01	Logístico	0.116123	0.009374248	450
A115	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 9	0.01	Logístico	0.112251	0.007950970	351
A116	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 9	0.01	Logístico	0.113474	0.008908030	321
A117	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 9	0.01	Logístico	<b>0.111438</b>	0.008929582	251
A118	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 9	0.01	Logístico	0.125385	0.008271771	196
A119	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 9	0.01	Logístico	0.117602	<b>0.005537725</b>	191
A120	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 9	0.01	Logístico	0.120287	0.009726798	167

Tabla 12

*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A121	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 10	0.01	Logístico	0.139654	0.008219490	358
A122	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 10	0.01	Logístico	0.125616	0.008839902	188
A123	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 10	0.01	Logístico	0.140534	0.007897024	145
A124	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 10	0.01	Logístico	0.120385	0.008711358	274
A125	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 10	0.01	Logístico	0.113914	0.007044961	252
A126	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 10	0.01	Logístico	0.111646	0.008132739	367
A127	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 10	0.01	Logístico	0.113587	0.005938426	220
A128	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 10	0.01	Logístico	0.112172	0.008996432	318
A129	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 10	0.01	Logístico	0.120023	0.007995318	257
A130	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 10	0.01	Logístico	0.112734	<b>0.005511856</b>	179
A131	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 10	0.01	Logístico	<b>0.106708</b>	0.007339301	393
A132	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 10	0.01	Logístico	0.112373	0.008739528	401

Tabla 13

*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A133	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 11	0.01	Logístico	0.116464	0.009666647	641
A134	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 11	0.01	Logístico	0.118840	<b>0.006684848</b>	351
A135	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 11	0.01	Logístico	0.117813	0.009962937	242
A136	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 11	0.01	Logístico	0.125438	0.009347961	132
A137	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 11	0.01	Logístico	0.120139	0.008472662	220
A138	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 11	0.01	Logístico	0.113591	0.007455515	288
A139	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 11	0.01	Logístico	0.151781	0.008543765	130
A140	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 11	0.01	Logístico	0.117270	0.006777660	240
A141	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 11	0.01	Logístico	0.111430	0.007034719	240
A142	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 11	0.01	Logístico	<b>0.111238</b>	0.007429383	243
A143	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 11	0.01	Logístico	0.136473	0.009073319	121
A144	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 11	0.01	Logístico	0.129131	0.009733710	136

Tabla 14

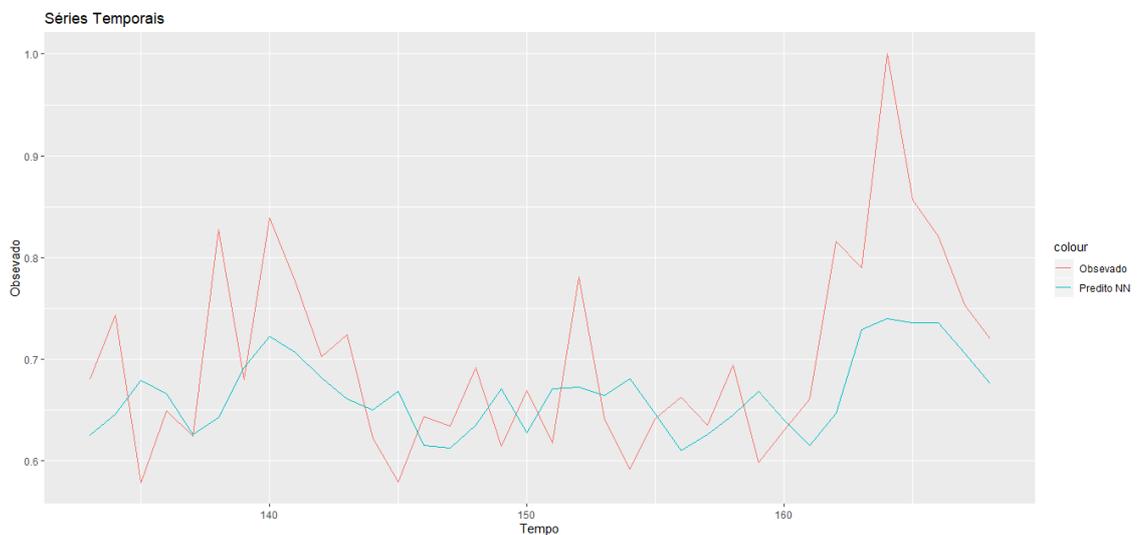
*Arquitectura con dos capas ocultas de los Arribos de turistas al departamento de Ancash, 2003 – 2017*

Arquitectura	Modelo	Capas ocultas	Neuronas	Umbral (criterio de detención)	Función de activación	Error	Umbral alcanzado	Número de pasos
A145	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	1 - 12	0.01	Logístico	0.126793	0.009894881	306
A146	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	2 - 12	0.01	Logístico	0.117931	0.006751961	549
A147	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	3 - 12	0.01	Logístico	0.119941	0.009051560	263
A148	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	4 - 12	0.01	Logístico	0.156206	0.009877884	144
A149	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	5 - 12	0.01	Logístico	0.140778	0.009903021	142
A150	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	6 - 12	0.01	Logístico	0.113311	0.009961243	262
A151	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	7 - 12	0.01	Logístico	0.107307	<b>0.006323985</b>	376
A152	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	8 - 12	0.01	Logístico	<b>0.098347</b>	0.009690201	280
A153	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	9 - 12	0.01	Logístico	0.121711	0.008130764	181
A154	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	10 - 12	0.01	Logístico	0.105945	0.007969631	204
A155	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	11 - 12	0.01	Logístico	0.113472	0.009521538	177
A156	$Y_{t+1} = Y_t + Y_{t-1} + Y_{t-2} + Y_{t-3} + Y_{t-4} + Y_{t-5} + Y_{t-6} + Y_{t-7} + Y_{t-8} + Y_{t-9} + Y_{t-10} + Y_{t-11}$	2	12 - 12	0.01	Logístico	0.104580	0.009757517	263

De la tabla 2 a la tabla 14, se observan los cálculos de los modelos de redes neuronales artificiales perceptrón multicapa, donde el modelo de arquitectura A21 es el que cuenta con la menor cantidad de la función de error (error = 0.091085) y un umbral alcanzado adecuado (umbral alcanzado = 0.0083943359), por lo que se realizó la obtención del modelo de arquitectura A21 y el pronóstico para el año 2018.

### ***Perceptrón multicapa con dos capas ocultas con 9 y 1 neurona en cada capa***

La obtención del perceptrón multicapa con dos capas ocultas de 9 y 1 neurona respectivamente, requirió 661 iteraciones en la corrección de la función del error, mediante el método de retropropagación.



**Figura 3.** Muestra de validación de la red neuronal con dos capas ocultas de los Arribos de turistas al departamento de Ancash.

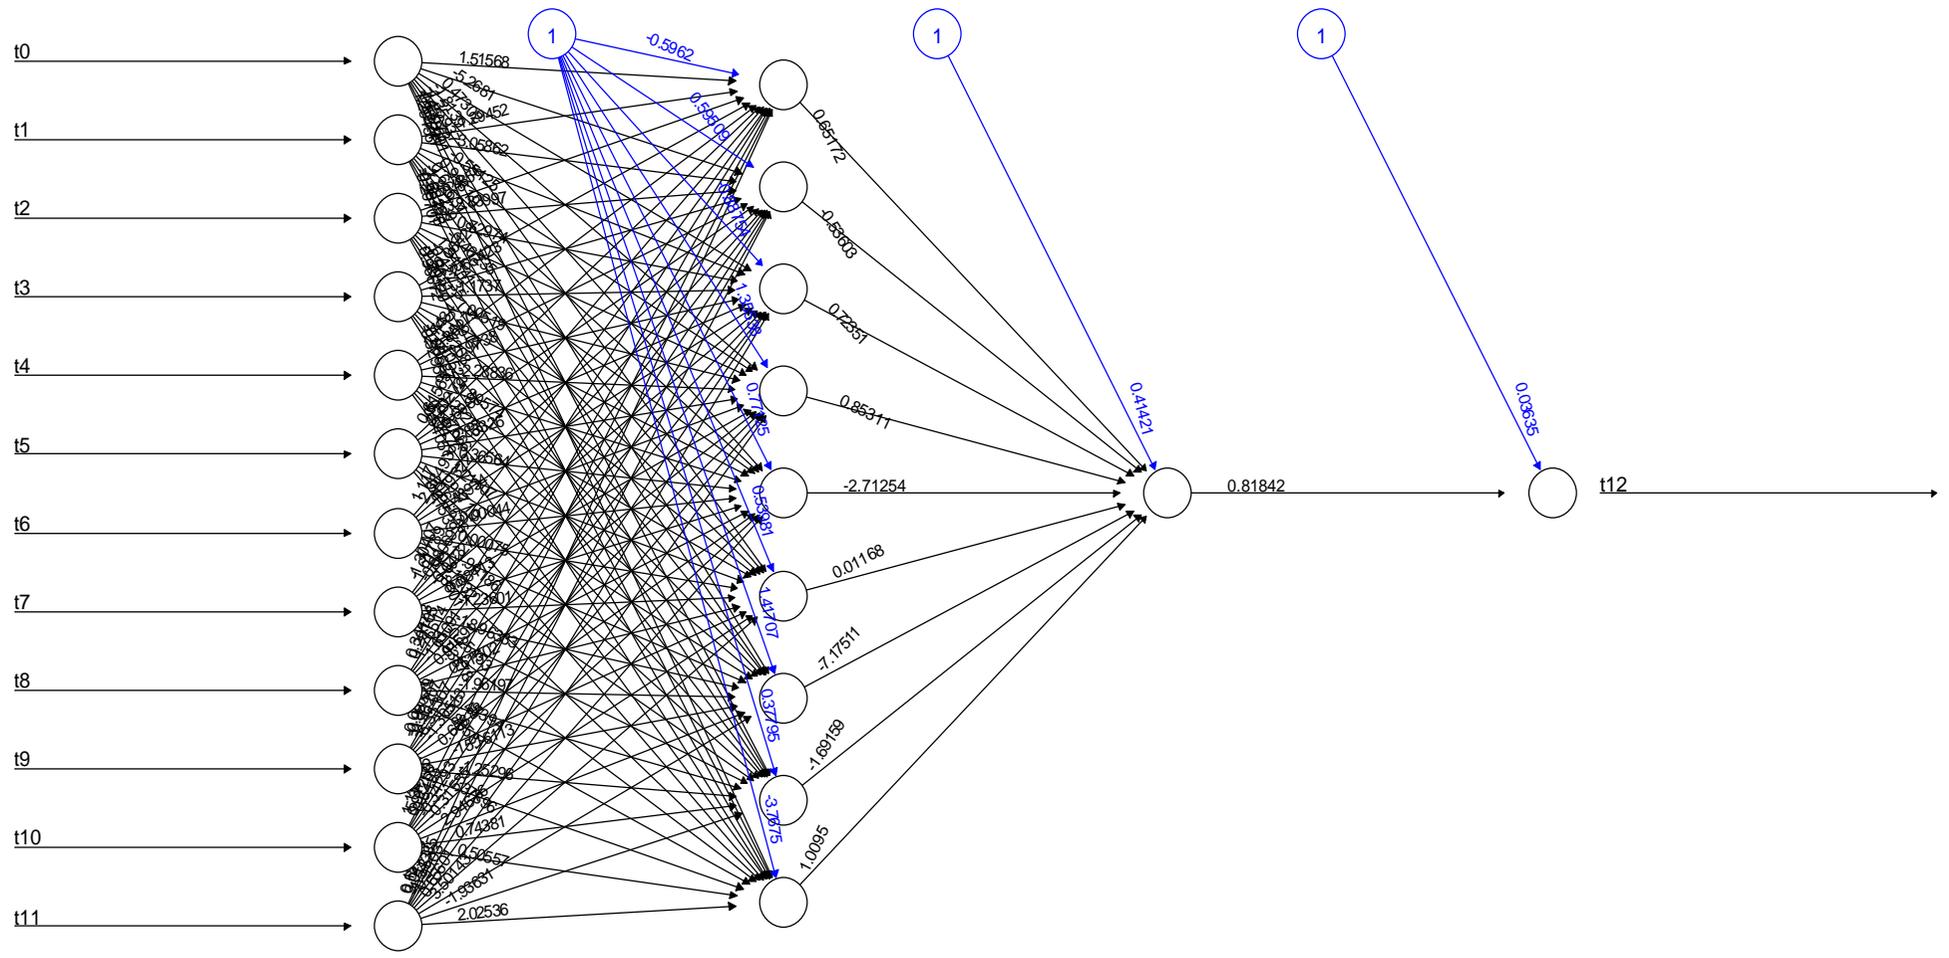


Figura 2. Perceptrón multipaca de una red neuronal artificial con dos capas ocultas de 9 y 1 neurona

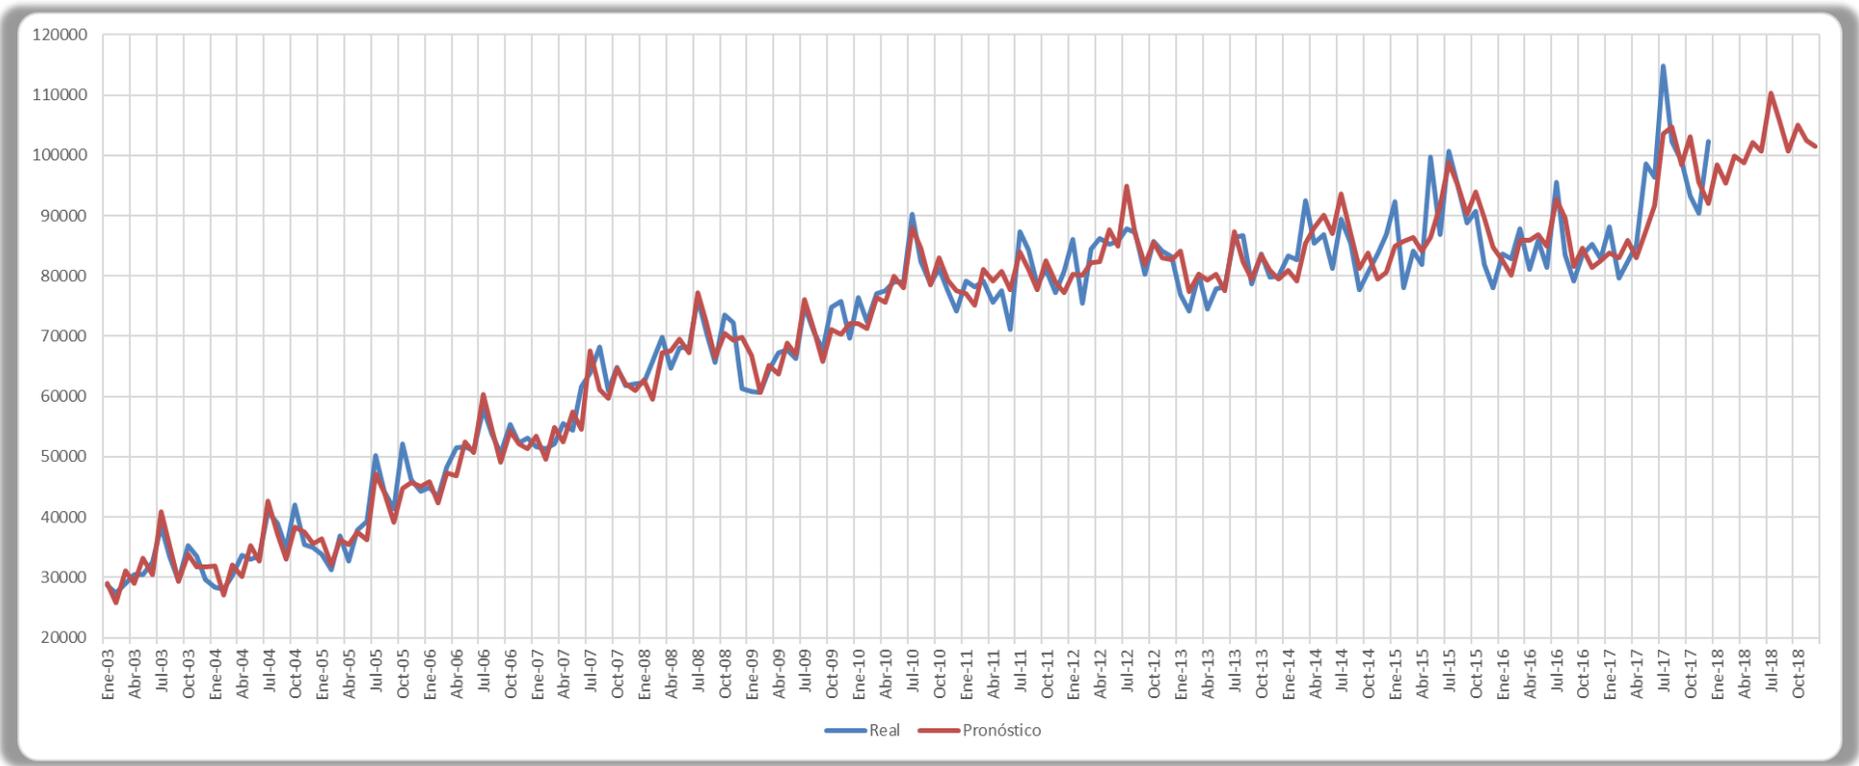


Figura 4. Pronóstico de los Arribos de turistas al departamento de Ancash para el año 2018

En la figura 3, se observa que los valores reales y los valores pronosticados presentan semejanza, la cual dicha diferencia en valores transformados de la variable presenta un error = 0.091085, siendo este valor adecuado para los pronósticos del año 2018.

Tabla 15

*Pronóstico de los Arribos de turistas al departamento de Ancash, 2018*

<b>Periodo</b>	<b>Pronóstico del turismo</b>
Ene-18	98387
Feb-18	95362
Mar-18	99867
Abr-18	98823
May-18	102222
Jun-18	100777
Jul-18	110277
Ago-18	105735
Set-18	100720
Oct-18	105103
Nov-18	102414
Dic-18	101505

De acuerdo a los resultados de la tabla 15, el pronóstico para el año 2018 sigue la forma de tendencia creciente, con un  $R^2 = 0.968$  y una suma de cuadrados del error real adecuada (RMSE = 3686.64)

## **5.2. Discusión de resultados**

El ajuste de los datos de series de tiempo del turismo en el departamento de Ancash, mediante el modelo de perceptrón multicapa de una red neuronal artificial

favorecieron su ajuste debido a que la serie de tiempo presentó tendencia y estacionalidad, adaptándose y comprendiendo el patrón de comportamiento pasado a fin de pronosticar el futuro, ello concuerda con lo mencionado por Sánchez & Velásquez (2010), donde indican que los modelos de redes neuronales favorecen su adaptabilidad a características desconocidas y no lineales.

Lo evidenciado por Escobar, Valdes & Zapata (2009), en cuanto a que las redes neuronales presentaron una gran capacidad de predicción de las series de tiempo obteniéndose errores absolutos medios porcentuales inferiores al 5%, lo cual los resultados del presente trabajo de tesis se asemeja ya que los errores resultantes fueron cercanos ( $\text{error} = 0.091085$ ), con un muy buen ajuste en todo el periodo estudiado, lo cual corrobora en que los modelos de redes neuronales son capaces de predecir el futuro en función a los hechos pasados. Estos resultados, también son acordes a lo indicado por Villada, Muñoz, & García-Quintero (2016), donde destacan la capacidad de estas redes para modelar sistemas complejos y obtener menores errores tanto en el entrenamiento como en la predicción. Así concuerda con lo mencionado por Jiménez-Carrión, Gutiérrez-Segura & Celi-Pinzón (2018), donde indican que las redes neuronales son una técnica altamente confiable, ya que como menciona Álvarez, Lau, Pérez, & Leyva (2016), las redes neuronales bien entrenadas son capaces de realizar predicciones correctas.

Faraway & Chatfield (1998), consideraron que sin una elección cuidadosa de la arquitectura, las funciones de activación y los valores de inicio apropiados para los pesos, las rutinas de ajuste pueden no converger, pueden converger a un mínimo local o pueden llevar a pronósticos que no son razonables. Agregar unidades ocultas adicionales aumenta el número de parámetros en un modelo de redes neuronales. Esto puede llevar a una mejora en el ajuste, pero puede llevar a un deterioro en las predicciones fuera de la muestra, lo cuál es ratificado en la arquitectura de la red neuronal aplicada al turismo en el departamento de Ancash, donde la función de activación fue logística debido a que los datos se transformaron previamente a un rango de 0 a 1, por lo que garantiza su uso adecuado de la función de activación. Del mismo modo, la cantidad de capas ocultas es importante ya que contar con muchas capas ocultas no garantizan un pronóstico adecuado, y mucho menos una mayor cantidad de neuronas en cada capa, toda esa elección debe realizarse en función la los errores en el entrenamiento y validación. Por otro lado, la elección de las entradas y salidas, como lo indica Zhang, Patuwo, & Hu (1998), no hay una forma explícita para explicar y analizar la relación entre entradas y salidas, ya que para nuestro caso la salida fue una y las entradas estuvieron conformados por 12 entradas, debido al criterio de la observación de estacionalidad en el comportamiento del turismo en el departamento de Ancash, con la finalidad de reproducir dicho patrón en el futuro.

La validación de los modelos de redes neuronales, tal como lo indicaron Acosta-Cervantes, Villarreal-Marroquín, & Cabrera-Ríos (2013), se utilizaron algoritmos de

optimización que minimizan una función de errores cuadrados de aproximación, las cuales fueron usados en el presente trabajo de tesis, con algoritmos que son llamados algoritmos de retropropagación, así como encontrar un conjunto de pesos que permitan una aproximación adecuada a datos conocidos se le denomina entrenamiento. Lo cual en el presente trabajo se utilizó una muestra de entrenamiento del 80% del total de los datos y del 20% para la muestra de validación por medio de la función de error. Así mismo, los modelos de redes neuronales son válidos pues se encargan únicamente de obtener el mínimo error tal como lo afirma Ortiz (2017), donde las RND usan un solo modelo, al cual se alimenta con los valores históricos que se van ajustando sus valores hasta llegar al valor buscado, de acuerdo al criterio de convergencia.

**CAPÍTULO VI: CONCLUSIONES, LIMITACIONES Y  
RECOMENDACIONES**

## CONCLUSIONES

- Se evaluó la capacidad predictiva del perceptrón multicapa de una red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018, en la cual se pudo evidenciar su alta capacidad de predicción y buen ajuste.
- Se diseñó la arquitectura de la red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018, la cuál estuvo compuesta por 12 variables entrada rezagadas en el tiempo y una variable de salida, con modelo de multicapa y retropropagación, con función de activación logístico, con dos capas ocultas de 9 y 1 neurona respectivamente, y un umbral de detención del 0.01.
- Se estableció el algoritmo de entrenamiento de la red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018, la cual estuvo compuesto por el 80% de los datos de la serie temporal y del 20% para la muestra de validación.
- Se determinó la validación del proceso de la red neuronal artificial aplicado al turismo en el departamento de Ancash, 2018, en la cual el modelo fue válido ya que presentó un umbral de 0.008394336, lo cual fue inferior al umbral 0.01 de la arquitectura inicial, además de presentar un error de tan solo 0.091085 y una capacidad predictiva de  $R^2 = 0.968$ , siendo este un muy buen ajuste a los datos de la serie temporal.

## **LIMITACIONES**

En la realización del presente trabajo de investigación existieron limitaciones en cuanto a material bibliográfico, ya que en la biblioteca de la facultad de ciencias no existen libros especializados en cuanto a redes neuronales perceptrón multicapa, por lo que se tuvo de optar por literatura especializada de repositorios institucionales y de revistas científicas.

## **RECOMENDACIONES**

A los responsables del sector turismo, para que prevean acciones que favorezcan al turismo en el departamento de Ancash, ya que se espera un crecimiento para el 2018.

A los estudiantes de la Escuela Académico Profesional de Estadística e Informática, para que profundicen sus conocimientos en temas de redes neuronales perceptrón multicapa.

Al director de escuela, para que capaciten a los docentes en temas de redes neuronales.

## REFERENCIAS BIBLIOGRÁFICAS

- Acosta-Cervantes, M., Villarreal-Marroquín, M., & Cabrera-Ríos, M. (2013). Estudio de validación de un método para seleccionar técnicas de pronóstico de series de tiempo mediante redes neuronales artificiales. *Ingeniería Investigación y Tecnología, XIV(I)*, 53-63.
- Álvarez, J., Lau, R., Pérez, S., & Leyva, E. (2016). Predicción de resultados académicos de estudiantes de informática mediante el uso de redes neuronales. *Ingeniare. Revista chilena de ingeniería, 24(4)*, 715-727. doi:<https://dx.doi.org/10.4067/S0718-33052016000400015>
- Andrés, M., & Misas, M. (Junio de 2007). Evaluación de pronósticos del tipo de cambio utilizando redes neuronales y funciones de pérdida asimétricas. *Revista Colombiana de Estadística, 30(1)*, 143-161. Obtenido de <https://revistas.unal.edu.co/index.php/estad/article/view/29446/29662>
- Barbachán, E., Fretelli, J., Rojas, C., & Tafur, K. (2017). Planeamiento Estratégico para la Industria Peruana de Turismo. Pontificia Universidad Católica del Perú, Escuela de Postgrado. Obtenido de [http://tesis.pucp.edu.pe/repositorio/bitstream/handle/123456789/8937/BARBACHAN\\_FRETELLI\\_PLANEAMIENTO\\_TURISMO.pdf?sequence=3&isAllowed=y](http://tesis.pucp.edu.pe/repositorio/bitstream/handle/123456789/8937/BARBACHAN_FRETELLI_PLANEAMIENTO_TURISMO.pdf?sequence=3&isAllowed=y)
- Bowles, P. (2010). *El cielo protector*. Barcelona: Seix Barral.
- Camarena, S., Del Castillo, B., Ramírez, B., & Zambrano, C. (2013). Una Revisión Literaria del Impacto del Turismo en el Desarrollo Económico. Lima, Perú.

- Camilo, J. (Junio de 2006). Predicción de series temporales con redes neuronales: una aplicación a la inflación colombiana. *Revista Colombiana de Estadística*, 29(1), 77-92. Obtenido de <https://revistas.unal.edu.co/index.php/estad/article/view/29171/29424>
- Cárdenas, Y., Sánchez, J., Soria, E., & Vargas, A. (2017). Planeamiento Estratégico del Sector Turismo en la Región Ancash. (P. U. PERÚ, Ed.)
- Escobar, L., Valdes, J., & Zapata, S. (2009). Redes Neuronales Artificiales en predicción de Series de Tiempo. Una aplicación a la Industria. *Ciencia y Tecnología*, 33-48. doi:<http://dx.doi.org/10.18682/cyt.v1i1>
- Faraway, J., & Chatfield, C. (1998). Time series forecasting with neural networks: a comparative study using the airline data. *Journal of Applied Statistics*, 47(2), 231-250.
- Gorunescu, F. (2011). *Data Mining: Concepts, Models and Techniques*. Rumania: Springer.
- Gutiérrez, A. (2012). *Probabilidad y estadística: enfoque por competencias*. México: McGraw-Hill.
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques*. Estados Unidos: Elsevier.
- Haykin, S. (2009). *Neural networks and learning machines*. New York: Pearson Prentice Hall.
- Hernández, R., Fernández, C., & Baptista, M. (2010). *Metodología de la investigación*. México: McGraw-Hill.

- Ibáñez, R., & Cabrera, C. (2011). *Teoría General del Turismo: un enfoque global y nacional*. México: Editorial Serie Didáctica Universidad Autónoma de Baja California Sur.
- Isasi, P., & Galván, I. (2004). *Redes de neuronas artificiales: un enfoque práctico*. España: Pearson Prentice Hall.
- Jiménez-Carrión, M., Gutiérrez-Segura, F., & Celi-Pinzón, J. (2018). Modelado y Predicción del Fenómeno El Niño en Piura, Perú mediante Redes Neuronales Artificiales usando Matlab. *Información tecnológica*, 29(4), 303-316. doi:<https://dx.doi.org/10.4067/S0718-07642018000400303>
- Organización Mundial del Turismo. (2011). *Introducción al turismo*. Madrid.
- Ortiz, F. (2017). Pronóstico de precios de petróleo: una comparación entre modelos GARCH y redes neuronales diferenciales. *Investigación Económica*, LXXVI(300), 105-126.
- Ospina, R., & Zamprogno, B. (Diciembre de 2003). Comparacao de algumas tecnicas de previsao em analise de series temporais. *Revista Colombiana de Estadística*, 26(2), 129-157. Obtenido de <https://revistas.unal.edu.co/index.php/estad/article/view/28680/28996>
- Pachas, C., & Vílchez, F. (2015). Planeamiento Estratégico de la Industria Hotelera para el Turismo receptivo. PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ.
- Sánchez, P., & Velásquez, J. (2010). Problemas de investigación en la predicción de series de tiempo con redes neuronales artificiales. *Avances en sistemas e Informática*, 7(3), 67-73.

- Valencia, M., Vanegas, J., Correa, J., & Restrepo, J. (2017). Comparación de pronósticos para la dinámica del turismo en Medellín, Colombia. *Lecturas de Economía*, 86, 199-230. doi:<http://dx.doi.org/10.17533/udea.le.n86a08>
- Villada, F., Muñoz, N., & García-Quintero, E. (2016). Redes Neuronales Artificiales aplicadas a la Predicción del Precio del Oro. *Información tecnológica*, 27(5), 143-150. doi:<https://dx.doi.org/10.4067/S0718-07642016000500016>
- Zhang, P. (2004). *Neural Networks in Business Forecasting*. Hershey, United States of America: Idea Group Publishing.
- Zhang, P., Patuwo, E., & Hu, M. (1998). Forecasting With Artificial Neural Networks: The State of the Art. *International Journal of Forecasting*, 14, 35-62.

## **ANEXOS**

## Anexo 1. Código R Project

```
#####  
### Series de tiempo con redes neuronales      ###  
#####  
  
### Paso 0: Limpieza de datos #####  
rm(list=ls())  
#####  
  
### Paquetes necesarios #####  
install.packages("quantmod")  
install.packages("neuralnet")  
install.packages("ggplot2")  
install.packages("reshape")  
#####  
  
### Paso 1: Lectura de datos #####  
library(readxl)  
Serie1<-read_excel("D:/Investigaciones/2018/Gary 5+10 de 30/Tesis/Turismo.xlsx",  
                  col_types = c("date", "date", "numeric"))  
View(Serie1)  
#####  
  
### Paso 2: Exploración y preparación de los datos #####  
class(Serie1)  
class(Serie1$E1)  
typeof(Serie1$E1)  
  
datoE1<-as.numeric(unlist(Serie1[3]))  
datoE1<-ts(matrix(datoE1),start=c(2003,1),end=c(2017,12),frequency =12)  
datoE1  
# Vizualizando los datos  
plot(datoE1,xlab =" Año Mes",ylab ="Número de turistas",col="darkblue")  
  
require(quantmod)  
#x1E1 <- Lag(datoE1,k=4)  
#x2E2 <- Lag(datoE1,k=3)  
#x3E3 <- Lag(datoE1,k=2)  
#x4E4 <- Lag(datoE1,k=1)  
#x0E0 <- Lag(datoE1,k=0)  
  
t0<-as.numeric(datoE1) #12 meses antes  
t0<-t0[-((length(t0)-11):length(t0))]
```

```

t1<-as.numeric(datoE1)[-1] #11 meses antes
t1<-t1[-((length(t1)-10):length(t1))]

t2<-as.numeric(datoE1)[-c(1,2)] #10 meses antes
t2<-t2[-((length(t2)-9):length(t2))]

t3<-as.numeric(datoE1)[-c(1:3)] #9 meses antes
t3<-t3[-((length(t3)-8):length(t3))]

t4<-as.numeric(datoE1)[-c(1:4)] #8 meses antes
t4<-t4[-((length(t4)-7):length(t4))]

t5<-as.numeric(datoE1)[-c(1:5)] #7 meses antes
t5<-t5[-((length(t5)-6):length(t5))]

t6<-as.numeric(datoE1)[-c(1:6)] #6 meses antes
t6<-t6[-((length(t6)-5):length(t6))]

t7<-as.numeric(datoE1)[-c(1:7)] #5 meses antes
t7<-t7[-((length(t7)-4):length(t7))]

t8<-as.numeric(datoE1)[-c(1:8)] #4 meses antes
t8<-t8[-((length(t8)-3):length(t8))]

t9<-as.numeric(datoE1)[-c(1:9)] #3 meses antes
t9<-t9[-((length(t9)-2):length(t9))]

t10<-as.numeric(datoE1)[-c(1:10)] #2 meses antes
t10<-t10[-((length(t10)-1):length(t10))]

t11<-as.numeric(datoE1)[-c(1:11)] #Un mes antes
t11<-t11[-((length(t11)-0):length(t11))]

t12<-as.numeric(datoE1)[-c(1:12)] #Variable dependiente
t12

STE1<-cbind(t0,t1,t2,t3,t4,t5,t6,t7,t8,t9,t10,t11,t12)
nrow(STE1)

#Normalización
range_datoE1<-function(x){(x-min(x))/(max(x)-min(x))}

```

```

STE1<-data.matrix(STE1)
min_data<-min(STE1)
max_data<-max(STE1)
STE1<-range_datoE1(STE1)
STE1
#Fin normalización

#nrow(STE1.Valida)
#nrow(STE1.Entrena)
#####

#Datos de entrenamiento
STE1.Entrena<-as.data.frame(STE1[1:132,]) #1:132 entrena
attach(STE1.Entrena)
STE1.Entrena[is.na(STE1.Entrena)] <- 0 #Asigna valores de "0" a los vacios "NA"
#Datos de validación
STE1.Valida<-as.data.frame(STE1[133:168,]) # 133:168 evalua
STE1.Valida

### PAso 3: Step 3 - Training a Model on the Data #####
set.seed(12345)
library("neuralnet")
maxit<-as.integer(1000000)

#####
nn <- neuralnet(t12~t0+t1+t2+t3+t4+t5+t6+t7+t8+t9+t10+t11,
               data=STE1.Entrena,hidden=c(9,1),
               threshold =0.01,stepmax= maxit)
#nn

#Presenta los valores
nn$result.matrix[c(1:3),1]

#Gráfico do modelo
plot(nn)

#Pronóstico
previsao<-compute(nn,STE1.Valida[,1:12])
previsao
#Valores da previsao
previsao.nn<-previsao$net.result
previsao.nn

```

```

#Gera as estimativas para o Random Walk
epsilon<-(STE1.Entrena[,13]-STE1.Entrena[,12])
mu<-mean(epsilon)
sigma2<-var(epsilon)

#Faz a previsao usando o Random Walk
previsao.rw<-STE1.Valida[,12]+rnorm(nrow(STE1.Valida),mu,sqrt(sigma2))

#Monta a base com as previsões
Tempo<-seq(169,181)
previsao.todos<-
as.data.frame(cbind(Tempo,STE1.Valida[,12],previsao.nn,previsao.rw))
colnames(previsao.todos)<-c("Tempo","Obsevado","Predito.NN", "Predito.RW")

#Faz o gráfico
#Faz o gráfico
library("ggplot2")
ggplot(previsao.todos, aes(Tempo)) +
  geom_line(aes(y = Obsevado, colour = "Obsevado")) +
  geom_line(aes(y = Predito.NN, colour = "Predito NN"))+
  #geom_line(aes(y = Predito.RW, colour = "Predito RW"))+
  ggtitle("Séries Temporais")

```