


**UNIVERSIDAD NACIONAL DE INGENIERÍA**

**FACULTAD DE INGENIERÍA INDUSTRIAL Y DE SISTEMAS**



**MODELO DE PRONÓSTICO DE PRECIOS DE ACCIONES  
EN LA BOLSA DE VALORES DE LIMA BASADO EN  
REDES NEURONALES ARTIFICIALES**

**TESIS**

Para optar el Título Profesional de

**INGENIERO DE SISTEMAS**

Bach. Mirko Jerber Rodríguez Mallma

Bach. Henry Marcos Valdivia Zevallos

**Lima – Perú**

**2012**

**Digitalizado por:**

Consortio Digital del  
Conocimiento MebLatam,  
Hemisferio y Dalse

**DEDICATORIA:**

*“A mis padres Julia e Yndalecio; por su apoyo incondicional, sin cuyo esfuerzo no vería realizado la culminación de este proyecto.”*

*Mirko*

*“A mis padres Esther y David, a mi esposa Moraima y a nuestro hijito Luke Darío David, por apoyarme siempre y ser la inspiración de mi vida”.*

*Henry*

## **AGRADECIMIENTOS**

Este trabajo es el resultado del esfuerzo conjunto de un grupo de personas. Por esto, en primer lugar, agradecemos a nuestros padres, quienes a lo largo de toda nuestra vida han apoyado y motivado nuestra formación académica, cuyo resultado se ve reflejado en la culminación satisfactoria del presente trabajo.

Además, agradecemos a nuestro Asesor Ing. Juan Carlos Sotelo Villena, al Jurado Especialista Ing. Walter Antaurco Trujillo y a la Presidenta del Jurado Ing. Doris Rojas Mendoza, quienes a lo largo de este tiempo han sido una fuente de consulta invaluable al compartir sus conocimientos para el desarrollo y culminación de este trabajo de investigación, el cual ha finalizado llenando todas nuestras expectativas.

## ÍNDICE

LISTA DE FIGURAS .....	IV
LISTA DE CUADROS .....	V
DESCRIPTORES TEMÁTICOS .....	VI
RESUMEN .....	VII
INTRODUCCIÓN .....	IX
<b>1. CAPÍTULO I - PLANTEAMIENTO DEL PROBLEMA.....</b>	<b>1</b>
1.1. SITUACIÓN PROBLEMÁTICA .....	1
1.2. FORMULACIÓN DEL PROBLEMA .....	3
1.3. JUSTIFICACIÓN DE LA INVESTIGACIÓN .....	3
1.4. OBJETIVOS DE LA INVESTIGACIÓN .....	4
1.4.1. <i>Objetivo General</i> .....	4
1.4.2. <i>Objetivos Específicos</i> .....	5
1.5. HIPÓTESIS Y VARIABLES .....	5
1.5.1. <i>Planteamiento de la Hipótesis</i> .....	5
1.5.2. <i>Identificación de variables</i> .....	5
1.5.3. <i>Operacionalidad de variables</i> .....	6
1.6. TIPO Y DISEÑO DE INVESTIGACIÓN .....	6
1.7. UNIDAD DE ANÁLISIS.....	7
1.8. POBLACIÓN DE ESTUDIO.....	7
1.9. TAMAÑO Y SELECCIÓN DE LA MUESTRA.....	8
<b>2. CAPÍTULO II - MARCO TEÓRICO.....</b>	<b>9</b>
2.1. ANTECEDENTES DEL PROBLEMA .....	9
2.2. BASES TEÓRICAS .....	12
2.2.1. <i>Mercado de Valores</i> .....	12
2.2.1.1. <i>Definición</i> .....	12

---

2.2.1.2.	Mercado de Valores en el Perú.....	12
2.2.1.3.	Estructura del Mercado de Valores en el Perú.....	13
2.2.1.4.	Regulación del Mercado de Valores en el Perú.....	14
2.2.1.5.	Valores negociados en el Mercado de Valores del Perú.....	14
2.2.1.6.	Organización del Mercado de Valores en el Perú.....	16
2.2.1.7.	Pronósticos en los Mercados de Valores.....	18
<b>2.2.2.</b>	<b>Redes Neuronales Artificiales.....</b>	<b>23</b>
2.2.2.1.	Modelo biológico.....	23
2.2.2.2.	Antecedentes.....	25
2.2.2.3.	Definición.....	26
2.2.2.4.	Características.....	26
2.2.2.5.	Campos de Aplicación.....	27
2.2.2.6.	Representación de una Neurona Artificial.....	29
2.2.2.7.	Representación de una Red Neuronal Artificial.....	29
2.2.2.8.	Procesamiento de información en una Red Neuronal Artificial.....	30
2.2.2.9.	Topología de las Redes Neuronales Artificiales.....	31
<b>2.3.</b>	<b>SERIES DE TIEMPO.....</b>	<b>33</b>
2.3.1.	Definición.....	33
2.3.2.	Descomposición de una serie de tiempo.....	33
2.3.2.1.	Modelo Aditivo.....	35
2.3.2.2.	Modelo Multiplicativo.....	36
2.3.3.	Pronósticos de series de tiempo.....	37
<b>2.4.</b>	<b>REDES NEURONALES ARTIFICIALES EN EL PRONÓSTICO FINANCIERO.....</b>	<b>44</b>
2.4.1.	Arquitectura de las Redes Neuronales Artificiales de tipo MLP.....	45
<b>3.</b>	<b>CAPÍTULO III - MODELO PROPUESTO.....</b>	<b>48</b>
3.1.	JUSTIFICACIÓN DEL MODELO PROPUESTO.....	48
3.2.	DESCRIPCIÓN DEL MODELO PROPUESTO.....	49
3.3.	ARQUITECTURA DEL MODELO PROPUESTO.....	49
3.4.	CONSTRUCCIÓN DEL MODELO DE REDES NEURONALES ARTIFICIALES.....	50
3.4.1.	FASE 1: Selección de variables.....	51
3.4.2.	FASE 2: Colección de datos.....	52
3.4.3.	FASE 3: Pre-procesamiento de datos.....	52
3.4.4.	FASE 4: Selección de conjuntos de entrenamiento y prueba.....	53
3.4.5.	FASE 5: Definición de la arquitectura.....	54
3.4.6.	FASE 6: Selección de la medida de rendimiento.....	56
3.4.7.	FASE 7: Entrenamiento de la red.....	57
3.4.8.	FASE 8: Implementación.....	58

<b>4. CAPÍTULO IV - UN SISTEMA DE PRONÓSTICO DE PRECIOS DE ACCIONES.....</b>	<b>59</b>
4.1. DESCRIPCIÓN DEL SISTEMA.....	59
4.2. REQUERIMIENTOS DEL SISTEMA.....	60
4.2.1. <i>Especificaciones Suplementarias.</i> .....	61
4.2.2. <i>Modelo de Casos de Uso.</i> .....	62
4.2.3. <i>Especificación de Casos de Uso.</i> .....	63
4.3. DISEÑO DEL SISTEMA.....	67
4.3.1. <i>Modelo de Diseño</i> .....	67
4.4. IMPLEMENTACIÓN DEL SISTEMA.....	69
4.4.1. <i>Módulos del Sistema</i> .....	69
<b>5. CAPÍTULO V - EXPERIMENTOS NUMÉRICOS.....</b>	<b>73</b>
5.1. HARDWARE Y SOFTWARE UTILIZADO.....	73
5.1.1. <i>Hardware</i> .....	73
5.1.2. <i>Software</i> .....	73
5.2. DATOS UTILIZADOS PARA LAS PRUEBAS.....	74
5.3. MODELO BOX-JENKINS (ARIMA) PARA LAS PRUEBAS.....	75
5.3.1. <i>Fase 1. Identificación del modelo</i> .....	76
5.3.2. <i>Fase 2. Estimación de parámetros</i> .....	82
5.3.3. <i>Fase 3. Verificación del modelo - Análisis de Residuos</i> .....	87
5.3.4. <i>Pronóstico con el modelo verificado</i> .....	90
5.4. MODELOS DE REDES NEURONALES ARTIFICIALES PARA LAS PRUEBAS.....	91
5.5. EXPERIMENTOS NUMÉRICOS.....	92
<b>CONCLUSIONES Y RECOMENDACIONES.....</b>	<b>96</b>
CONCLUSIONES.....	96
RECOMENDACIONES.....	98
<b>GLOSARIO DE TÉRMINOS.....</b>	<b>100</b>
<b>BIBLIOGRAFÍA.....</b>	<b>102</b>
<b>ANEXOS.....</b>	<b>107</b>
<b>ANEXO 1. ÍNDICES FINANCIEROS.....</b>	<b>107</b>

## LISTA DE FIGURAS

Figura 2.1 Estructura del Mercado de Valores del Perú.....	14
Figura 2.2 Estructura de la neurona biológica.....	24
Figura 2.3 Representación de una neurona artificial. ....	29
Figura 2.4 Red Neuronal Artificial de 3 capas.....	30
Figura 2.5 Componentes para el procesamiento de información en una RNA. .....	31
Figura 2.6 Clasificación de las Redes Neuronales Artificiales. ....	32
Figura 2.7 Diagrama de flujo para la construcción de un modelo Box-Jenkins. .....	40
Figura 2.8 Arquitectura de una red de tipo MFNN.....	45
Figura 3.1 Arquitectura de la RNA propuesta. ....	50
Figura 3.2 Metodología para la construcción de un modelo de RNA.....	51
Figura 4.1 Diagrama de Paquetes del Sistema .....	62
Figura 4.2 Diagrama de Casos de Uso del Sistema .....	63
Figura 4.3 Diagrama de Clases de Diseño del Sistema .....	68
Figura 4.4 Módulo de Carga de Datos del Sistema.....	70
Figura 4.5 Estructura de los datos de Entrada del Sistema.....	70
Figura 4.6 Módulo de Procesamiento del Sistema.....	71
Figura 4.7 Módulo de Reportes del Sistema .....	72
Figura 4.8 Reporte gráfico del comportamiento del pronóstico.....	72
Figura 5.1 Ploteo de la data de entrenamiento. ....	77
Figura 5.2 Tendencia de la data de entrenamiento.....	78
Figura 5.3 Auto correlación y autocorrelación parcial de la data de entrenamiento.....	79
Figura 5.4 Ploteo de la data de entrenamiento con dif. de orden 1.....	80
Figura 5.5 Auto correlación y Autocorrelacion parcial de la data de entrenamiento con dif. de orden 1.....	81
Figura 5.6 Auto correlación y Auto correlación parcial de los residuos. ....	89
Figura 5.7 Curva pronosticada vs curva real.....	90
Figura 5.8 Gráfico del pronóstico utilizando el Modelo 2.....	94
Figura 5.9 Gráfico del pronóstico utilizando el Modelo 6.....	94

## LISTA DE CUADROS

<i>Tabla 2.1 Patrones de autocorrelación de los procesos AR, MA y ARMA.....</i>	<i>43</i>
<i>Tabla 2.2 Medidas de Rendimiento Común para Predicciones.....</i>	<i>47</i>
<i>Tabla 3.1 Ejemplo de formación de conjuntos de entrenamiento.....</i>	<i>54</i>
<i>Tabla 4.1 Características del sistema .....</i>	<i>60</i>
<i>Tabla 4.2 Especificaciones Suplementarias del Sistema .....</i>	<i>61</i>
<i>Tabla 4.3 Especificación de Caso del Uso: Cargar datos. ....</i>	<i>63</i>
<i>Tabla 4.4 Especificación de Caso de Uso: Definir conjuntos de entrenamiento y prueba.....</i>	<i>64</i>
<i>Tabla 4.5 Especificación de Caso de Uso: Definir parámetros de entrenamiento....</i>	<i>65</i>
<i>Tabla 4.6 Especificación de Caso de Uso: Procesar entrenamiento. ....</i>	<i>65</i>
<i>Tabla 4.7 Especificación de Caso de Uso: Calcular indicadores de rendimiento. ....</i>	<i>66</i>
<i>Tabla 4.8 Especificación de Caso de Uso: Generar reportes. ....</i>	<i>67</i>
<i>Tabla 5.1 Información Básica del Emisor de Volcan.....</i>	<i>74</i>
<i>Tabla 5.2 Información Básica de Volcan.....</i>	<i>74</i>
<i>Tabla 5.3 Modelos y Topologías de prueba. ....</i>	<i>92</i>
<i>Tabla 5.4 Resultados obtenidos para cada uno de los modelos de prueba. ....</i>	<i>92</i>



## **DESCRIPTORES TEMÁTICOS**

1. Mercado de valores.
2. Pronósticos financieros.
3. Inteligencia Artificial.
4. Redes Neuronales Artificiales.
5. Metodología Box Jenkins (Arima).

## **RESUMEN**

En este trabajo de investigación se desarrolla un modelo de pronóstico capaz de predecir el comportamiento de los índices de precios y cotizaciones de las acciones comercializadas en la Bolsa de Valores de Lima, tomando como base el uso de técnicas de inteligencia artificial; específicamente las Redes Neuronales Artificiales.

El modelo considera para el pronóstico, datos cuantitativos históricos del precio de las acciones. Se aprovecha la capacidad de las Redes Neuronales Artificiales de trabajar con datos cuantitativos no lineales y su capacidad de aprendizaje, aplicado a problemas de pronósticos financieros.

El principal aporte de esta investigación es demostrar que el modelo propuesto basado en el uso de Redes Neuronales Artificiales es capaz de obtener aproximaciones de mejor calidad en el pronóstico de las series de tiempo financieras, que aquellas generadas por métodos tradicionales como los conocidos y ampliamente utilizados métodos Box-Jenkins.

## **ABSTRACT**

In this research work, a forecasting model is development to predict the behavior of indices and stock prices traded on the Lima Stock Market, based on the use of artificial intelligence; specifically the Artificial Neural Networks.

The proposed model considers in the forecast the quantitative historical data of stock Price. The aim is to harness the power of Artificial Neural Networks to work with non-linear quantitative data and their capacity for learning, applied to financial forecast problems

The main contribution of this researching is to demonstrate that the proposed model based on Artificial Neural Networks is able to get better quality forecasting approximations of financial time series, than those generated by traditional methods such as known and widely used Box-Jenkins methods.

## INTRODUCCIÓN

La presente tesis es una investigación que tiene por objetivo evaluar la factibilidad del uso de las técnicas de Inteligencia Artificial, específicamente la técnica de Redes Neuronales Artificiales, en el pronóstico del comportamiento de los precios de acciones comercializadas en la Bolsa de Valores de Lima, para lo cual se tomó como caso de estudio el comportamiento de los precios de las acciones comercializadas en la Bolsa de Valores de Lima de una de las empresas más grandes del sector minero en el Perú, en el periodo comprendido entre enero del 2007 y junio del 2012.

El pronóstico realizado utilizando el modelo propuesto basado en Redes Neuronales Artificiales se comparó contra los resultados obtenidos utilizando una metodología de pronóstico estadística tradicional, la metodología ARIMA, obteniéndose como resultado de la experimentación que la aplicación de la técnica de Redes Neuronales Artificiales en el comportamiento del pronóstico del precio de acciones en el Mercado de valores del Perú, obtienen mejores aproximaciones y el pronóstico es más exacto.

En la primera parte - Capítulo I, titulada "Planteamiento del Problema", se describe y presenta la situación problemática, se definen los objetivos de la investigación y se plantea la hipótesis.

La segunda parte - Capítulo II, nos presenta el marco teórico bajo el cual se circunscribió el desarrollo de esta tesis, se abarcan temas referidos al comportamiento y naturaleza de los mercados de valores, se profundiza en el tratamiento de las series de tiempo de tipo financiera y los métodos tradicionales utilizados para describir su comportamiento; finalmente se presenta en este capítulo la aplicación de la técnica de RNA en el pronóstico de series de tiempo de tipo financieras y los resultados obtenidos.

La tercera parte - Capítulo III, propone la construcción de un modelo de pronóstico basado en RNA y la metodología utilizada para su construcción y definición.

La cuarta parte - Capítulo IV, nos presenta el desarrollo e implementación de un sistema de pronóstico que utiliza las técnicas de RNA, se propone la construcción de un sistema con diferentes parámetros, el cual está construido en lenguaje JAVA.

La quinta parte - Capítulo V, nos presenta los experimentos numéricos llevados a cabo para validar los resultados obtenidos con el modelo propuesto, en este capítulo también se realiza un estudio del pronóstico realizado con la metodología tradicional ARIMA y sus resultados se compararon contra los obtenidos con el modelo propuesto basado de RNA.

Finalmente se presenta los resultados obtenidos y las conclusiones de la investigación.

# **CAPÍTULO I**

## **PLANTEAMIENTO DEL PROBLEMA**

### **1.1. Situación Problemática.**

Desde el surgimiento de los mercados bursátiles, se ha buscado intensamente formas y/o criterios para descifrar las fluctuaciones de los precios de las acciones, bonos, contratos, etc. que allí se comercializan. Diversas investigaciones han dado origen a técnicas y metodologías para el análisis financiero, algunas más eficientes que otras, sin embargo los patrones de las series de tiempo financieras han demostrado ser muy difíciles de detectar, lo cual generalmente lleva a concluir que éstas series de tiempo son aleatorias y que las predicciones son prácticamente inútiles, tanto a corto plazo como a largo plazo [Burton 2003].

Sin embargo, tales aseveraciones han sido objetadas por una serie de investigadores y especialistas en Finanzas, afirmando que si es posible conseguir cierto grado de predicción de los eventos futuros a partir de conocimientos del pasado. Así, diversos analistas técnicos, valiéndose de cifras históricas y demás estadísticas del mercado de valores, se aventuran a pronosticar el comportamiento de los precios de las Acciones en el tiempo.

No comparten la idea de los que creen que los precios siguen un comportamiento aleatorio, argumentando que el estudio de los precios y las estadísticas pueden ser de gran utilidad para pronosticar el comportamiento de los precios con un buen grado de certeza [Rueda 2005].

Los analistas bursátiles disponen, hoy en día de distintas herramientas para observar la evolución del mercado bursátil y predecir el futuro de las cotizaciones de las acciones que allí se comercializan. Por un lado existe el Análisis Fundamental que incluye variables del entorno (expansión o recesión económica, variaciones de las tasas de interés y de los tipos de cambio, políticas económicas esperadas, evolución de la balanza de comercio y de pagos, déficit fiscal o superávit, etc.) y por otro lado el Análisis Técnico, que se basa en hechos históricos, datos cuantitativos del pasado, lo que ya ocurrió y, a partir de ello, el participante del mercado puede dar su pronóstico [Rueda 2005].

Debido a que el mercado no se comporta de una manera lineal, y que en la predicción es necesario incluir variables provenientes tanto del Análisis Fundamental como del Análisis Técnico, en los últimos años, se han desarrollado una serie de investigaciones sobre la aplicación de métodos alternativos y multidisciplinarios en el análisis de los mercados financieros, tales como: La Teoría del Caos, Fractales, Wavelets, Máquinas de Vectores de Soporte, Modelos Ocultos de Markov, Inteligencia Artificial y combinaciones de estos métodos [Lijuan 2002].

El presente trabajo de investigación se centra en el uso de tecnologías de inteligencia artificial, específicamente las Redes Neuronales Artificiales, para desarrollar y construir un modelo adecuado que logre una mejor aproximación en el pronóstico del comportamiento de los precios de las acciones, frente a métodos tradicionales de pronósticos utilizados en el mercado de valores del Perú.

## **1.2. Formulación del Problema.**

¿Utilizar un modelo de pronóstico de precios de acciones en la Bolsa de Valores de Lima basado en Redes Neuronales Artificiales puede mejorar, en porcentaje, el nivel de exactitud del pronóstico frente a técnicas estadísticas de regresión tradicionales como la metodología Arima (Box Jenkins)?.

## **1.3. Justificación de la Investigación.**

El sistema financiero es a las economías, lo que los pulmones al cuerpo humano; los recursos que mueve el mercado de valores son como el oxígeno vital que las entidades necesitan para subsistir, desarrollarse y crecer, así como éste circula por el cuerpo para permitirle que viva, así también los mercados de valores captan, concentran y dispersan el dinero a los distintos agentes que hacen la economía para que ésta se mueva y desarrolle. [Rueda 2005]

El análisis del mercado de valores con propósitos de inversión es una actividad difícil y ningún método, por complejo o completo que sea, elimina el riesgo inherente a esta clase de inversiones. Si el inversionista tuviera certeza sobre las circunstancias que existirán en un tiempo dado, la preparación de un pronóstico sería trivial, pero dado, que la incertidumbre es un elemento que siempre va a estar presente en situaciones de pronósticos, los investigadores desarrollan diferentes metodologías que permitan reducir dicho riesgo, algunas basadas en matemáticas o estadísticas, y otras con teorías más complejas que involucran modernos sistemas computacionales como redes neuronales, lógica difusa, sistemas neurodifusos, programación genética y evolutiva y la teoría del caos, herramientas enmarcados en el paradigma de la Inteligencia Artificial.

Hoy en día existe un gran interés por el uso de tecnologías de Inteligencia Artificial como apoyo a la toma de decisiones en el sector



financiero y específicamente en el mercado bursátil, tal es así que existen diversos sistemas automatizados como TradingSolutions, que utilizan las Redes Neuronales Artificiales para el pronóstico de indicadores bursátiles utilizados por un gran número de analistas del mercado bursátil [Zapata 2004].

A la fecha no existen investigaciones en el campo de los pronósticos en los mercados financieros en el Perú que utilicen técnicas de Inteligencia Artificial, y dado que los existentes han sido aplicados principalmente a mercados de países desarrollados; este trabajo de investigación pretende mostrar la capacidad de las técnicas de Inteligencia Artificial de realizar pronósticos de series de tiempo financieras, como herramienta alterna a las técnicas estadísticas tradicionales, que proporcione información pertinente con un mayor grado de precisión a Inversionistas, Analistas Bursátiles, Empresas Financieras y demás interesados, que les permita invertir en los mercados de valores con un riesgo de pérdidas más bajo, y por tanto tomar mejores decisiones de inversión.

Por todo lo anterior, existe la necesidad de desarrollar un marco conceptual que permita fundamentar la propuesta metodológica de la presente tesis, y elaborar una investigación empírica con el fin de comprobar las hipótesis planteadas.

## **1.4. Objetivos de la Investigación.**

### **1.4.1. Objetivo General.**

Desarrollar un modelo de pronóstico de precios de acciones aplicando la técnica de Redes Neuronales Artificiales, que realice un pronóstico con menor grado de error comparado con técnicas estadísticas convencionales como la metodología Arima (Box Jenkins), en la Bolsa de Valores del Perú.

### **1.4.2. Objetivos Específicos.**

- Definir la topología adecuada de la Red Neuronal Artificial a utilizar en el modelo, que permita un realizar el pronóstico de precios de acciones en la Bolsa de Valores de Lima con menor grado de error.
- Validar por comparación la superioridad del modelo basado en Redes Neuronales Artificiales frente a la metodología Box Jenkins (ARIMA).

## **1.5. Hipótesis y variables.**

### **1.5.1. Planteamiento de la Hipótesis.**

“El modelo de pronóstico basado en Redes Neuronales Artificiales, ajusta y pronostica de manera más precisa el precio de una acción cotizada en la Bolsa de Valores de Lima”.

### **1.5.2. Identificación de variables.**

- **Variable Independiente (X).**

Modelo de Red Neuronal Artificial, el cual está definido por: número de capas ocultas, número de neuronas de la capa oculta, tipo de algoritmo de aprendizaje, número de iteraciones, número de observaciones para la predicción y porcentaje de la muestra de entrenamiento.

Modelo<sup>1</sup>: Esquema teórico, generalmente en forma matemática, de un sistema o de una realidad compleja, como la evolución económica de un país, que se elabora para facilitar su comprensión y el estudio de su comportamiento.

---

<sup>1</sup> Diccionario de la Lengua Española. Real Academia Española. Vigésima segunda edición. 2001.

- **Variable Dependiente (Y).**

Predicción del comportamiento diario del precio de una determinada acción en el mercado de valores peruano (Bolsa de Valores de Lima: BVL).



### **1.5.3. Operacionalidad de variables.**

En cuanto a las variables independientes, se realizarán experimentos modificando los parámetros del Modelo de Red Neuronal Artificial: número de capas ocultas, número de neuronas de la capa oculta y número de iteraciones, con el objetivo de determinar la arquitectura de mejor desempeño que permita un pronóstico adecuado.

Para el caso de la variable dependiente, se obtendrá el pronóstico de cada uno de los experimentos realizados con la arquitectura de la Red Neuronal Artificial de mejor desempeño y se comparará contra los resultados obtenidos mediante los métodos tradicionales Box-Jenkins (ARIMA). La comparación se realizará a través de la medición de errores obtenidos en el proceso de experimentación, el detalle se muestra en el Capítulo 5.

### **1.6. Tipo y Diseño de Investigación.**

El diseño de investigación constituye el plan o la estrategia que se desarrolla para obtener la información que se requiere en una investigación [Hernandez+ 2010].

En el enfoque cuantitativo en el que se enmarca esta investigación, se requiere la aplicación de un diseño de investigación para analizar la certeza de la hipótesis formulada en el contexto de la creación de un nuevo modelo de predicción de indicadores financieros para aportar evidencia respecto de los lineamientos de ésta investigación.

En esta sección presentaremos los criterios y decisiones metodológicas que se han ido adoptando para encontrar el camino más idóneo en el análisis y desarrollo de la investigación a partir de las sugerencias de autores y estudios previos. Es por ello que esta investigación se define como de tipo experimental, es decir, se realiza el estudio centrado en la implementación de un experimento en el que se manipulan intencionalmente las variables independientes (supuestas causas-antecedentes), para analizar las consecuencias que la manipulación tiene sobre la variable dependiente (supuestos efectos-consecuencias), dentro de una situación de control.

### **1.7. Unidad de análisis.**

El comportamiento del precio de la acción de una Entidad Emisora de Valores, esto es, una empresa que cotiza sus acciones en el mercado de valores del Perú, en el intervalo de tiempo comprendido entre los años 2007 y 2011.

### **1.8. Población de estudio.**

La población de estudio lo constituyen las *Empresas Emisoras de Valores*, que participan en el mercado de valores del Perú, de un determinado tamaño y pertenecientes a un sector específico de la actividad económica: AFPs, Bancos y Financieras, Compañías de Seguros, Empresas Industriales, Mineras y otros.

## **1.9. Tamaño y selección de la muestra.**

Para el caso de modelos de pronóstico de series de tiempo financieras, se considera muestras (Empresa(s) Emisora(s) de Valores) extraídas de un determinado sector económico y de que pertenezcan a un tamaño específico (grande, mediana o pequeña), con el objetivo de evitar la heterogeneidad de las poblaciones [Lizarraga 1996].

Para este estudio de investigación se ha considerado uno de los sectores más importantes de la actividad económica peruana: Sector Minero, además se ha elegido una empresa de tamaño Grande: *Volcan*, la cual junto a la Empresa *Antamina* ocuparon el segundo lugar en la producción de Zinc en el año 2010 [Vademecum BVL 2010].

Una vez elegida la muestra, para la construcción de modelos de pronósticos, nos enfrentamos al reto de definir la unidad temporal, que comprende el periodo de tiempo a considerar para la extracción de los datos de tipo histórico existentes en las distintas fuentes de datos. Normalmente, estos periodos son anuales y oscilan entre los tres hasta los diez años, siendo el promedio de cinco años muy común en estudios que se han desarrollado.

Para este estudio de investigación se ha tratado en lo posible de considerar un periodo temporal en el que no exista demasiadas variables de tipo aleatoria (conflictos sociales, inflación, cambios abruptos del tipo de cambio, etc.) que influyan significativamente en el comportamiento de los indicadores financieros a predecir. Teniendo en cuenta la crisis financiera mundial que afectó de manera particular a la minería metálica de nuestro país en el año 2009, haciendo retroceder su producción en 1.4%, luego de veinte años de crecimiento consecutivo y de haber obtenido una expansión significativamente alta en el 2008 (7.4%) [Vademecum BVL 2010], hemos considerado el análisis de los datos históricos de los precios de las acciones en un periodo de 5 años: desde el año 2007 hasta el 2011.

## **CAPÍTULO II**

### **MARCO TEÓRICO**

#### **2.1. Antecedentes del Problema.**

En el área financiera, el estudio de la predictibilidad de los precios de las acciones en un mercado de valores ha sido ampliamente abordado, en ese sentido, el uso de herramientas y métodos para tal fin han ido evolucionando y mejorando en sofisticación a través del tiempo, teniendo hoy en día un amplio abanico de modelos, herramientas y métodos (unos más exactos que otros) para la predicción de distintos tipos de indicadores en un mercado bursátil.

De la gran cantidad de estudios respecto de la predictibilidad del comportamiento en el mercado financiero, se pueden destacar los estudios mencionados a continuación:

- En 1996; Hua y Yann [Jung-Hua+ 1996], desarrollan un modelo de redes neuronales recurrentes para hacer predicciones a mediano plazo del mercado accionario de Taiwan en su estudio titulado "Stock market trend prediction using ARIMA-based neural networks", para lo cual usaron características obtenidas del análisis ARIMA.

Los resultados permitieron observar que entrenando la red con datos semanales con cuatro años de historia, se pueden obtener buenas predicciones del mercado en un horizonte de seis meses.

- En el 2000; Fernández, González y Sosvilla [Fernández+ 2000], desarrollan una regla de negociación para el Índice General de la Bolsa de Madrid utilizando redes neuronales y análisis técnico en su estudio titulado "On the profitability of technical trading rules based on artificial neural networks: Evidence of Madrid stock market". Llegando a la conclusión que dicha regla obtiene mejores rendimientos de forma consistente frente a una estrategia Buy & Hold mientras el mercado se encuentra estable o a la baja, pero que cuando el mercado se encuentra en tendencia alcista, la mejor estrategia es la pasiva. Por su parte, en el 2003; Chen, Leung y Daouk [Chen+ 2003] buscan modelar y predecir la dirección de los retornos del Índice de la Bolsa de Acciones de Taiwán a través de estrategias de negociación con base en redes neuronales probabilísticas, obteniendo mejores rendimientos que la estrategia Buy & Hold.
- Parisi y Guerrero [Parisi+ 2003] a través del uso de redes neuronales artificiales hacen predicciones de los cambios de signo semanales de los índices bursátiles Bovespa (Brasil), CAC40 (Francia), Dow Jones Industrial (Estados Unidos), FTSE100 (Reino Unido), GDAX (Alemania), Hang Seng (Hong Kong), KLS (Malasia), Nikkei225 (Tokio), STI (Tailandia) y S&P500 (USA), encontrando que esta técnica presenta mayor poder predictivo sobre las series estudiadas frente a modelos ARIMA.
- Álvarez y Álvarez [Alvarez+ 2003], utilizan Algoritmos Genéticos y Redes Neuronales Artificiales para predecir los precios del Yen y la Libra Esterlina. Adicionalmente, hacen una fusión de datos a través de la cual combinan los resultados obtenidos por ambos métodos con el fin de mirar la existencia de sinergias para mejorar los resultados en la predicción. Pese a lo sofisticado de las herramientas no se ve una mejora considerable en los resultados de predicción de tipos de cambio frente a trabajos anteriores.

En el caso específico del Perú, el desarrollo de modelos de predictibilidad respecto del mercado de valores ha sido muy escaso, sin embargo existen algunos trabajos de investigación en los cuales se ha aplicado de manera exitosa algunas técnicas de inteligencia artificial, dentro de las cuales podemos destacar:

- Ojeda [Ojeda 2009], propone la aplicación de un modelo de predicción para controlar la demanda de energía eléctrica en empresas industriales en el Perú, basado en Redes Neuronales Artificiales.
- Vilcapoma [Vilcapoma 2003], propone un modelo de Data Mining basado en Redes Neuronales Artificiales para la identificación de patrones de evasión tributaria en la Superintendencia Nacional de Administración Tributaria para mejorar el uso de los recursos humanos en la fiscalización de contribuyentes.
- Quispe y Robles [Quispe+ 2002], proponen la elaboración de un Sistema Experto para la determinación del monto de autoevaluó basado en información tributaria y aplicado a una entidad Municipal del Perú. Para la construcción de dicho sistema, utilizaron las Redes Neuronales Artificiales para la identificación de patrones de comportamiento en base a la información predial.
- Sallehuddín y otros [Sallehuddín+ 2009], proponen un modelo híbrido para la predicción de diferentes índices económicos y financieros asiáticos. El modelo propuesto es una combinación de redes neuronales tipo Grey Relational Artificial Neural Networks (GRANN) y un modelo lineal ARIMA. Obtienen como resultado que el modelo híbrido propuesto presenta una mejor predicción que los demás modelos con los que fue comparado.

De todo lo anterior, podemos manifestar que se han desarrollado una serie de estudios de investigación respecto de modelos de predicción en la última década, primando el uso de técnicas de Redes Neuronales Artificiales, sin embargo su desarrollo en el Perú no ha sido importante,



llegándose a utilizar sólo en algunos estudios de investigación enfocados y aplicados a otro tipo de problemáticas distintas de la financiera. Este estudio de investigación pretende ampliar la discusión sobre el tema del uso de técnicas de inteligencia artificial para establecer nuevos modelos de predicción aplicados al sector financiero y específicamente al mercado de valores peruano.

## **2.2. Bases Teóricas**

### **2.2.1. Mercado de Valores.**

#### **2.2.1.1. Definición.**

Los mercados de valores son aquellos donde se negocian valores y derivados emitidos por empresas u organismos con algún riesgo y que con frecuencia, pagan dividendos e intereses. A este segmento del mercado de capitales concurren ofertantes y demandantes de valores mobiliarios en donde se transan valores negociables desde su emisión, primera colocación y transferencia hasta la extinción del título. En este mercado intervienen unidades deficitarias y superavitarias y actúan como intermediarios los bancos, las instituciones financieras y la bolsa de valores a través de sus agentes de intermediación. Está formado por el mercado primario y secundario [Website BVL 2010].

Es importante indicar que en este mercado se llevan a cabo transacciones con distintos instrumentos, entre los cuales se pueden mencionar: instrumentos accionarios, instrumentos de deuda (bonos), instrumentos de efectivo e instrumentos derivados.

#### **2.2.1.2. Mercado de Valores en el Perú.**

La historia de la actividad bursátil en el Perú tiene su origen en 1860 con la creación de la Bolsa Mercantil de Lima. Nuestro mercado de valores es uno

de los de mayor tradición en América Latina. Gran parte de estos años la regulación y supervisión de las operaciones bursátiles recayó completamente en la misma Bolsa de Valores hasta que en 1970 aparece la Comisión Nacional Supervisora de Empresas y Valores CONASEV.

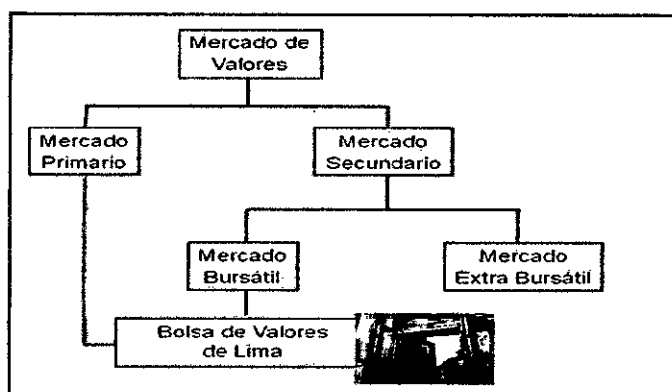
### **2.2.1.3. Estructura del Mercado de Valores en el Perú.**

La clasificación más usual del Mercado de Valores distingue a los mercados primarios y mercados secundarios. Ambos mercados son recíprocamente complementarios. A su vez, éste último se compone del mercado bursátil y del mercado extrabursátil.

Tanto el mercado primario como el secundario son recíprocamente complementarios. La existencia de un mercado primario de valores, hace posible la presencia de un mercado secundario de valores.

El mercado primario, es aquel donde se efectúan ventas de valores recién emitidos a los compradores originales, motivo por el cual es denominado mercado de nuevas emisiones. Se llevan a cabo las ofertas públicas primarias de acciones, bonos e instrumentos de corto plazo, asimismo, las emisiones privadas y las emisiones de los gobiernos.

El mercado secundario, es aquél donde se efectúan transacciones que implican simples transferencias de activos financieros ya existentes y por lo tanto, el volumen de tales operaciones refleja el grado de liquidez del mercado. Este es un mercado de reventa, el cual permite nuevamente tener liquidez a los tenedores de valores.



**Figura 2.1 Estructura del Mercado de Valores del Perú**

#### **2.2.1.4. Regulación del Mercado de Valores en el Perú.**

El Estado regula el Mercado de Valores Peruano a través de una Ley principal (la Ley del Mercado de Valores) en la que se establecen los objetivos que informan la regulación de esa materia [López+ 1996]. En ese sentido, el Régimen legal del Mercado de Valores Peruano lo constituyen las disposiciones legales más importantes que regulan la actividad del mercado de valores, las cuales se encuentran contenidas en la Ley del Mercado de Valores, así como en la normatividad vigente emanadas de un órgano especial: Comisión Nacional Supervisora de Empresas y Valores (CONASEV).

#### **2.2.1.5. Valores negociados en el Mercado de Valores del Perú.**

Los valores o instrumentos financieros negociados en el Mercado de Valores del Perú son [WEB BVL. 2010]:

**Valores de Renta Variable:** Son aquellos cuya rentabilidad, medida básicamente por los cambios de su precio o cotización en Bolsa, es variable (cambia) en función a diferentes factores tales como: la coyuntura internacional y nacional, desempeño y resultados de la empresa, política de dividendos, expectativas, etc. Otorgan a su poseedor derechos de propiedad sobre el patrimonio de la empresa.

- Acciones comunes
- Acciones de inversión
- Certificados de suscripción preferente
- Cuotas de participación de fondos de inversión

**Valores Representativos de Deuda:** Son aquellos cuya rentabilidad se mide básicamente en términos de una tasa de interés fija (pactada sin cambios para el periodo de la emisión), o de una tasa de interés determinada (que puede variar a lo largo del periodo de emisión, lo que debe ser informado por la empresa antes de su colocación). Otorgan a su poseedor derechos crediticios.

•**Bonos:**

- ✓ Corporativos
- ✓ Subordinados
- ✓ De arrendamiento financiero
- ✓ Deuda soberana (Bonos Soberanos y del Tesoro)
- ✓ Hipotecarios
- ✓ De titulización

También se pueden negociar valores en el Mercado de Instrumentos de Emisión no Masiva (MIENM):

- ✓ Pagarés
- ✓ Letras de cambio
- ✓ Facturas

**Importante:** En el MIENM la negociación es de valores NO inscritos. Todos estos valores deben estar registrados en una institución de compensación y liquidación de valores.

### **2.2.1.6. Organización del Mercado de Valores en el Perú.**

Existen cuatro participantes fundamentales en todo mercado de valores:

#### **A) Los Reguladores.**

La regulación del Mercado de Valores por parte del Estado está a cargo de la Comisión Nacional Supervisora de Empresas y Valores (CONASEV). A diferencia de algunos otros países, el ente regulador del sector público en Perú está especializado únicamente en el mercado bursátil y no tiene participación en la supervisión de otros mercados como el bancario o el de seguros.

La CONASEV es una institución pública del sector economía cuya finalidad es promover el mercado de valores, velar por la transparencia, la correcta formación de precios y la protección de los inversionistas, procurando la difusión de toda la información necesaria para la adopción de las decisiones financieras relativas a los valores y la igualdad de trato a todos ellos. Asimismo, se encarga de dictar las normas que regulan el mercado de valores, así como de supervisar y controlar las diferentes instituciones que participan en dicho mercado.

#### **B) Los Intermediarios.**

En Perú actualmente sólo se encuentra en operación la Bolsa de Valores de Lima (BVL). A través de la BVL operan las Sociedades de Agentes de Bolsa. Cada Sociedad de Agentes de Bolsa está facultada por Ley para administrar fondos de inversión, para operar en el exterior con títulos de Deuda Pública Externa del Perú, para realizar préstamos de valores y operaciones de reporte, para fungir como fiduciario en fideicomisos de titulización y para operar con derivados.

Finalmente, es importante mencionar dentro de la estructura de la intermediación en el mercado de valores peruano el papel que juega la Caja de Valores y Liquidaciones CAVALI [Rodríguez 1998]. Esta sociedad

anónima creada en mayo de 1997 tiene por objeto la liquidación de operaciones y el registro de valores representados por anotaciones en cuenta como producto de la nueva tendencia a la desmaterialización del mercado bursátil en Perú.

### **C) Los Inversionistas.**

Inversor. Persona natural o jurídica que invierte sus recursos en la adquisición de acciones, obligaciones u otro activo financiero buscando rentabilidad y liquidez, así como obtener ganancias en las transferencias de valores. Los inversionistas en las sociedades anónimas tienen responsabilidad limitada: arriesgan sólo el dinero que invierten. Los inversionistas se preocupan de dos características cruciales de un portafolio: su tasa esperada de retorno y el riesgo.

#### **Inversionista individual**

Personas naturales que tienen excedentes de recursos (ahorros) y que buscan la mejor alternativa de inversión para poder colocar su dinero y así obtener una rentabilidad adecuada. Adquieren o venden títulos en cantidades menores. Se considera inversionista individual al público en general y entidades no especializadas en adquirir valores mobiliarios.

#### **Inversionista institucional**

Los principales demandantes de valores mobiliarios son los inversionistas institucionales [Sachs+ 1994] como las Asociaciones de Fondos de Pensiones (AFP's), Empresas de Seguros, Agentes de Intermediación, Fondos Mutuos, Fondos de Inversión, Bancos, Financieras.

Las AFP's han sido las principales compradoras de valores (bonos) en las emisiones locales de los diferentes países.

## **D) Los Emisores.**

Empresas o entidades gubernamentales que emiten valores con la finalidad de obtener dinero para financiar sus actividades.

Las empresas emisoras o agentes deficitarios son aquellas que requieren fondos, sea para financiar un nuevo proyecto de inversión o para reestructurar sus pasivos con un financiamiento, generalmente de largo plazo.

La importancia de las empresas emisoras radica en que constituyen la fuente del mercado primario (emisión primaria) que da origen al mercado de capitales, al generar nuevas ofertas de valores, sean éstas ofertas públicas o privadas.

### **2.2.1.7. Pronósticos en los Mercados de Valores.**

Es evidente que para obtener ganancias en el mercado bursátil se requiere comprar una acción a un precio dado y venderla cuando haya alcanzado un precio superior, por tanto es importante en esta clase de inversión predecir con altas probabilidades de certeza que una acción subirá de precio en un periodo de tiempo razonable para entonces venderla y tomar utilidades.

Alcanzar éste objetivo no es fácil debido a que existen gran cantidad de elementos y variables que pueden influir sobre el comportamiento del mercado accionario, por ello, el trabajo del pronóstico se basa en la identificación de las variables y patrones más apropiados para anticipar la tendencia de los precios de los instrumentos financieros.

En gran cantidad de campos y actividades se debe tener una visión del comportamiento futuro de muchas variables críticas antes de tomar decisiones, estas dependen de los pronósticos y por tanto se esperan que sean lo suficientemente precisos y confiables.

Puesto que el futuro es incierto, los pronósticos en general no serán perfectos y mejor aún que suministrar un dato numérico, su objetivo es reducir el error de estimación. Por ello, los pronósticos son usados principalmente, para hacer insinuaciones del comportamiento futuro de un sistema y apoyar los procesos de planeación y toma de decisiones.

#### **2.2.1.7.1. Clasificación de los Métodos de Pronóstico.**

Los métodos para obtener pronósticos se clasifican ampliamente en cualitativos y cuantitativos [Mendoza 2010].

Los primeros son subjetivos e intuitivos, la posición central en estos métodos no la tienen los datos pasados, sino la experiencia, el conocimiento y el buen juicio de los expertos, son útiles cuando los datos son escasos. Generalmente estos pronósticos no pueden ser reproducidos por alguien más, puesto que el pronosticador no indica claramente como fue incorporada la información disponible en el pronóstico. Según la metodología seguida, los métodos cualitativos pueden ser:

**Exploratorios o Prospectivos:** Cuando se parte de las experiencias pasadas y presentes para proyectar al futuro, sopesando las diferentes posibilidades.

**Normativos o Deductivos:** Cuando se procede al revés, es decir, se parte de las metas u objetivos a lograr en el futuro y se analiza qué se necesita para lograrlos y eso da una pauta para pensar cuando sucederán los eventos previstos para el futuro.

Los pronósticos basados en modelos matemáticos o estadísticos son los cuantitativos; una vez se señala el modelo y la técnica se pueden determinar automáticamente los pronósticos correspondientes para ser reproducidos cuando se necesiten. La información utilizada consiste en datos históricos, que se encuentra en forma numérica y corresponde a los registros de las



propias empresas o información oficial de diverso origen. Los métodos cuantitativos son de dos tipos según la información en que se basen:

**Métodos de Series de Tiempo:** Cuando se usa información de la misma variable que se va a pronosticar, buscando encontrar el patrón del pasado y proyectarlo al futuro.

**Métodos Causales:** Cuando se utiliza información de la variable que se va a pronosticar y de otras variables que influyen en ella o que se relacionan y cuyo pronóstico es más simple.

#### **2.2.1.7.2. Técnicas de Análisis Bursátil.**

Existen muchos métodos que buscan dar información que oriente la difícil decisión de que acción comprar o vender y cuándo hacerlo. Los dos acercamientos principales para el estudio del mercado bursátil son el análisis fundamental y el análisis técnico. Cada uno de estos métodos, involucra diferentes teorías y tienen sus propias ventajas y limitaciones [Marín+ 2002].

##### **A) Análisis Fundamental.**

Este método parte del supuesto de que los movimientos de los precios de las acciones tienen causas económicas, financieras o de otro tipo, las cuales pueden identificarse y ponderarse antes de producir su efecto en el mercado. Por tanto, el método, consiste en conocer y evaluar la situación financiera de los mercados, tanto en el entorno macroeconómico como en las condiciones microeconómicas de la empresa.

El uso de este método involucra factores de diversa índole que pueden afectar potencialmente la oferta y demanda de acciones. Algunos son:

**Económicos:** PIB, inflación, tasa cambiaria de pesos a dólares, tasas de interés, circulante, precio internacional del petróleo, rendimiento de otras alternativas de inversión.

**Políticos:** Regulación gubernamental.

**Sicológicos:** Ánimo de los inversionistas, incertidumbre.

**Características de la empresa:** Análisis de estados financieros, utilidades, índices.

**Análisis estratégico de la empresa:** Productos, accionistas, planes de expansión, competencia, tecnología.

Dentro de las limitaciones del Análisis Fundamental, se destacan el retraso en la publicación de los balances y cuentas de resultados (trimestre vencido según legislación colombiana) de las sociedades que cotizan en bolsa, constituye una importante limitación, dado que los estados financieros son la base para el análisis fundamental.

Además las cuentas antes de ser publicadas ya han sido conocidas por personas que tienen acceso privilegiado a la información, y por tanto, están en capacidad de aventajar a otros inversionistas en la toma de decisiones.

Asimismo, es factible que las empresas alteren o maquillen sus estados financieros en un período determinado, proporcionando así, parámetros no reales de comparación con otras empresas.

## **B) Análisis Técnico.**

El análisis técnico a diferencia del fundamental, no estudia las variables económicas, sino que estudia directamente los movimientos que se han producido en el mercado, observando exclusivamente la evolución de las

cotizaciones a lo largo de un periodo de tiempo, a fin de predecir futuras tendencias. Este tipo de análisis tuvo sus orígenes a finales de 1880 y fue introducido por Charles H. Dow.

El análisis técnico hace por tanto una interpretación de los precios históricos de las acciones como elemento predictivo de su comportamiento futuro. Su argumento es la formación de los precios mediante interacciones y relaciones entre la oferta y demanda (comportamiento humano), las cuales pueden ser descompuestas en patrones que identifican las tendencias y con ello el comportamiento futuro [MARÍN, 2000].

Para entender el mercado bursátil, el análisis técnico se apoya en varios postulados: [MARÍN, 2000]

- Sostener que los fenómenos de la bolsa reflejan el sentimiento y la actitud de grupos humanos, impredecibles individualmente; pero es sabido que, el comportamiento humano puede predecirse cuando forma parte de un grupo.
- Establecer que en el mediano a largo plazo, los movimientos de los precios de una emisora y de los índices bursátiles no son aleatorios o desordenados, sino que tienen una estructura con una lógica propia, de tal manera que forman patrones repetitivos que permiten entenderlos y predecir lo que vendrá.
- Postular que no se tiene que conocer la causa de un fenómeno del mercado para poder entenderlo y por tanto, puede predecirse lo que con mayor probabilidad resultará en el corto, mediano o largo plazo, conociendo solamente los precios históricos de la acción.

El elemento básico de análisis es la curva de cotizaciones, que permite conocer la evolución de un título a través del tiempo, y mediante la interpretación de las líneas y figuras que se forman, se identifican tendencias y patrones del precio. Otras herramientas de análisis son los gráficos de volumen y el manejo de indicadores.

Uno de las grandes ventajas del análisis técnico es que se adapta prácticamente a cualquier entorno operativo y dimensión de tiempo, pero también se ha cuestionado la validez de sus postulados.

Sin embargo, entre las principales críticas que suele hacerse al enfoque técnico es que la formación de figuras es muy subjetiva, es decir, donde un analista ve una determinada figura otro puede no verla. También se discute el hecho de considerar que la historia se repite, es decir, que estudiando el pasado se puede prever el futuro y finalmente, de acuerdo a la teoría del paseo aleatorio [Velásquez 2004], los precios se mueven de forma aleatoria e impredecible, lo cual cuestiona el postulado que afirma que los precios presentan tendencias.

Los Modelos matemáticos simplifican y conceptualizan eventos de la naturaleza utilizando formulaciones de ecuaciones matemáticas a ser resueltas. Sin embargo, su utilización en situaciones complejas donde se incluyen factores socio-psicológicos, como en el caso de los negocios, la gestión y las finanzas, resulta casi imposible [Gil-Lafuente 2005]. Los modelos basados en Redes Neuronales Artificiales sin embargo, modelan y describen fenómenos imprecisos y complejos utilizando operaciones lógicas para llegar a una conclusión.

## **2.2.2. Redes Neuronales Artificiales.**

### **2.2.2.1. Modelo biológico.**

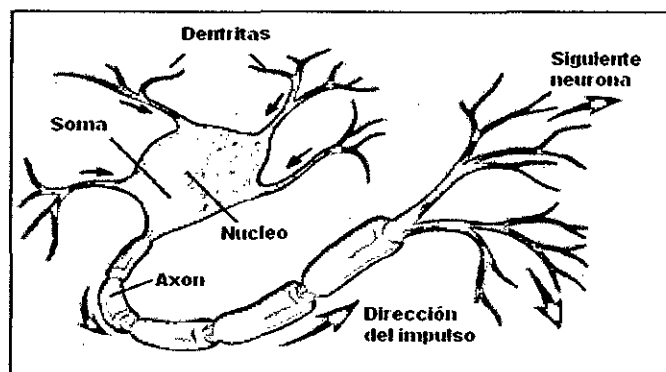
El cerebro de los humanos (y animales) está compuesto por células llamadas neuronas las cuales son únicas, en el sentido que no se reproducen para reemplazarse a ellas mismas, más bien se atrofian y pierden capacidad para intercambiar información con las neuronas que le rodean [Trippi+ 1996], se estima que el número de neuronas en un humano está en el orden de los 100 billones. Las neuronas funcionan en grupos

llamados redes, cada grupo contiene varios miles de neuronas altamente interconectadas, este fenómeno puede explicar porque los seres humanos podemos retener información. El cerebro, por tanto, puede verse como una colección de redes neuronales.

Una neurona es una célula, cuyo tamaño y forma es variable, no existen neuronas iguales, sin embargo cada una de ellas posee características propias que las diferencian de las demás: soma, núcleo y axón.

El cuerpo de la neurona o **soma** contiene el **núcleo** y se encarga de todas las actividades metabólicas, además recibe la información de otras neuronas vecinas a través de las conexiones sinápticas.

Las **dendritas** son las conexiones de entrada de la neurona. Por su parte el **axón** es la salida de la neurona y se utiliza para enviar impulsos o señales a otras células nerviosas. Cuando el axón está cerca de sus células destino se divide en muchas ramificaciones que forman sinapsis con el soma o axones de otras células. Esta unión puede ser inhibitoria o excitadora según el transmisor que las libere. Cada neurona recibe de 10.000 a 100.000 sinapsis y el axón realiza una cantidad de conexiones similar.



**Figura 2.2** Estructura de la neurona biológica.  
*Fuente:* [Trippi+ 1996].

El sistema de neuronas biológico está compuesto por neuronas (células) de entrada (sensores) conectados a una compleja red de neuronas calculadoras (neuronas ocultas), las cuales, a su vez, están conectadas a las neuronas de salidas que controlan, por ejemplo, los músculos.

#### **2.2.2.2. Antecedentes.**

El intento por explicar el funcionamiento del cerebro humano, se remonta a las ideas de Walter Pitts quien junto Warren McCulloch intentaron explicar el funcionamiento del cerebro humano, por medio de una red de células conectadas entre sí para experimentar ejecutando operaciones lógicas [McCulloch+ 1943].

En 1949, el fisiólogo Donald O. Hebb de la McGill University, expuso que las redes neuronales podían aprender. Su propuesta tenía que ver con la conductividad de la sinapsis, es decir, con las conexiones entre neuronas. En 1949, Hebb expuso, en su teoría conocida como *Teoría Hebbiana*, que la repetida activación de una neurona por otra a través de una sinapsis determinada, aumenta su conductividad, y la hacía más propensa a ser activada sucesivamente, induciendo a la formación de un circuito de neuronas estrechamente conectadas entre sí [Hebb+ 1949].

En el verano de 1951, Marvin Minsky y Dean Edmonds montaron la primera máquina de redes neuronales, compuesta básicamente de 300 tubos de vacío y un piloto automático de un bombardero B-24. Llamaron a su creación *Stochastic Neural Analog Reinforcement Calculator (SNARC)*, se trataba de una red constituida por 40 neuronas artificiales que imitaban el funcionamiento del cerebro de una rata.

El desarrollo de investigaciones respecto de formas como emular el funcionamiento del cerebro a partir de la comprensión de las neuronas y su estructura, se desarrollaron rápidamente a lo largo del tiempo, existiendo actualmente, numerosas investigaciones que se han agrupado en una rama más general llamada Inteligencia Artificial.

### **2.2.2.3. Definición.**

Las Redes Neuronales Artificiales (RNA) son una tecnología de procesamiento de información inspirada en estudios acerca del funcionamiento del cerebro y del sistema nervioso [Trippi+ 1996]. Lo que realmente intentan modelar las RNA, y los grupos estructurados e interconectados de varias de ellas, es interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico y de este modo se construyen sistemas que presentan un cierto grado de inteligencia [Hilera+ 1995].

Una RNA es un software de computadora que imita la capacidad del cerebro humano de: clasificar patrones, realizar pronósticos o tomar decisiones basadas en experiencias pasadas [GATELY, 1996].

Una de las principales propiedades de las RNA es la capacidad de aprender y generalizar a partir de ejemplos reales. La teoría y modelado de las RNA está inspirada en la estructura y funcionamiento de los sistemas nerviosos donde la neurona es el elemento fundamental. Una de las características que diferencia a las neuronas del resto de las células vivas es su capacidad de comunicación entre ellas. [Hilera+ 1995].

### **2.2.2.4. Características.**

Se pueden distinguir las siguientes características:

- **Adaptabilidad.**

Las RNA se adaptan fácilmente a su entorno, modificando su sinapsis (conexión con otras neuronas). Aprenden de la experiencia generalizando conceptos a partir de casos particulares.

- **Memoria Distribuida.**

Se dice que la información y por tanto el conocimiento, se encuentra distribuido por la sinapsis de la red, de modo que si una sinapsis queda dañada, no perdemos más que una parte muy pequeña de la información.

- **Procesamiento Paralelo.**

Como en el caso del cerebro humano, una RNA, pone en marcha simultáneamente millones de neuronas para, por ejemplo, analizar una imagen, reconocer un rostro, etc., tarea que un ordenador común no podría realizar.

- **Auto-organización.**

Consiste en la modificación de la red completa, creando su propia organización, para lograr un objetivo específico.

- **Operación en Tiempo Real.**

Una RNA puede realizar grandes procesos de datos de forma muy rápida, debido a su implementación paralela.

#### **2.2.2.5. Campos de Aplicación.**

Se pueden distinguir los siguientes campos de aplicación:

- **Modelización de sistemas.**

En esta aplicación el propósito es determinar un modelo del sistema a partir de unas entradas y salidas de éste que se conocen.



- **Predicción.**

El objetivo perseguido en estas aplicaciones es determinar el valor de una secuencia temporal en un instante a partir de los valores en los instantes anteriores. Dentro de este campo nos encontramos con aplicaciones:

- **Farmacológicas.**

- ✓ Determinación de la concentración en sangre de un determinado fármaco.
- ✓ Previsión del consumo de un determinado fármaco por un Hospital.
- ✓ Predicción del número de pacientes en un Hospital.

- **Medio ambiente.**

- ✓ Determinación del nivel de ozono.

- **Económicas.**

- ✓ Predicción en el mercado bursátil de un determinado valor.
- ✓ Evolución del número de consumidores para un determinado producto.
- ✓ Predicción del consumo eléctrico, en agua, etc. de una gran ciudad.

- **Clasificación.**

En esta aplicación el objetivo perseguido es clasificar el patrón de entrada en una serie de clases definidas de antemano. En este campo nos encontramos aplicaciones:

- **Médicas.**

- ✓ Identificación de pacientes con enfermedades de difícil diagnóstico.
- ✓ Clasificación de tumores.
- ✓ Determinación de tipos de arritmias.
- ✓ Identificación de parámetros característicos en electrocardiogramas.

- **Farmacológicas.**

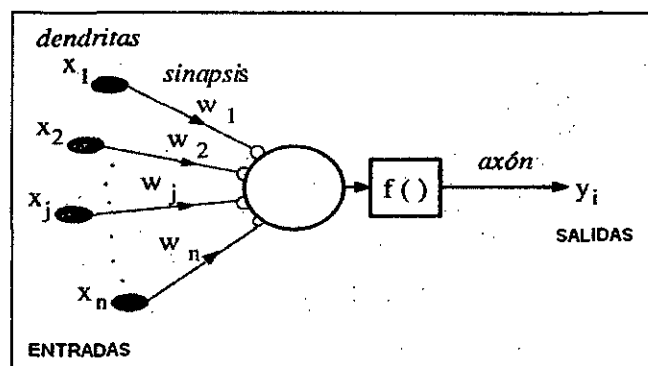
- ✓ Identificación de pacientes con efectos secundarios para un fármaco.

### 2.2.2.6. Representación de una Neurona Artificial.

La Neurona Artificial puede ser representada como un grafo constituido por un conjunto de nodos, donde uno de ellos representa el Núcleo y el resto las Dendritas. Cada neurona recibe información de entrada a través de estímulos, procesa la información y genera una señal de salida.

Los nodos que representan las Dendritas estarán conectados al Núcleo. El grado de Estímulo o Inhibición (sinapsis) de las entradas está representado por pesos:  $W_1, \dots, W_n$

Un peso positivo (+) significa que existe un Estímulo asociado a dicha entrada, en cambio un peso negativo (-) representa una Inhibición. La Figura 2.3 muestra esta representación.

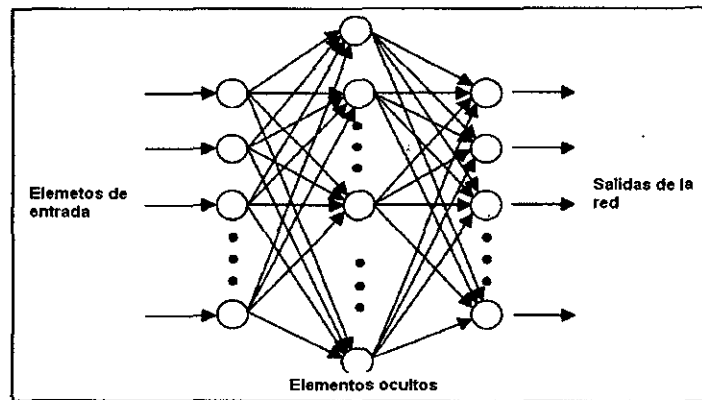


**Figura 2.3** Representación de una neurona artificial.  
*Fuente:* Elaboración propia según [Hilera+ 1995].

### 2.2.2.7. Representación de una Red Neuronal Artificial.

Una RNA está compuesta de una colección de neuronas artificiales interconectadas. Las neuronas de la red se encuentran distribuidas en

diferentes capas de neuronas, de manera que las neuronas de una capa están conectadas con las neuronas de la capa siguiente, a las que pueden enviar información. La Figura 2.4 muestra una estructura básica compuesta de 3 capas.



**Figura 2.4** Red Neuronal Artificial de 3 capas.  
**Fuente:** [Trippi+ 1996].

#### 2.2.2.8. Procesamiento de información en una Red Neuronal Artificial.

Una vez que la estructura de la RNA ha sido establecida, el procesamiento de información se lleva a por cada una de las neuronas  $N_i$  que operan con los valores numéricos recibidos  $X_i$  (entradas) desde las neuronas de la capa anterior, teniendo en cuenta el peso sináptico  $W_i$  de la conexión por la que recibieron dichos valores, dando más importancia a la información que le llegue por una conexión de peso mayor.

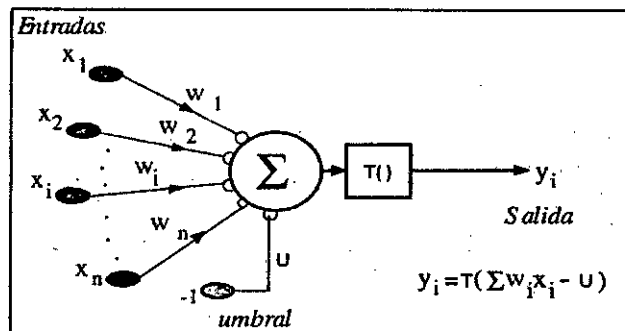
Con las entradas y los pesos se suele hacer diferentes tipos de operaciones a través de una función de sumarización o regla de propagación  $F$ . Una de las operaciones más comunes es sumar las entradas, pero teniendo en cuenta la importancia de cada una de estas. Por tanto, un modelo simple de la función  $F$  sería:

$$F = X_1W_1 + X_2W_2 + \dots + X_nW_n$$

El valor obtenido a partir de la regla de propagación, se filtra a través de una función llamada función de activación o función de transferencia  $T$ . El resultado de esta función proporciona la salida. La forma de estas funciones la elige el investigador de acuerdo al objetivo que se trace, siendo las principales las funciones tipo: escalón, lineal y mixta, sigmoideal, tangente sigmoideal y gaussiana.

Con frecuencia se añade al conjunto de pesos de una neurona, un parámetro adicional  $U$ , que se denomina umbral, que se resta del potencial postsináptico, por lo que el argumento de la función de activación  $T$  queda como:  $\sum(X_i W_i - U)$ .

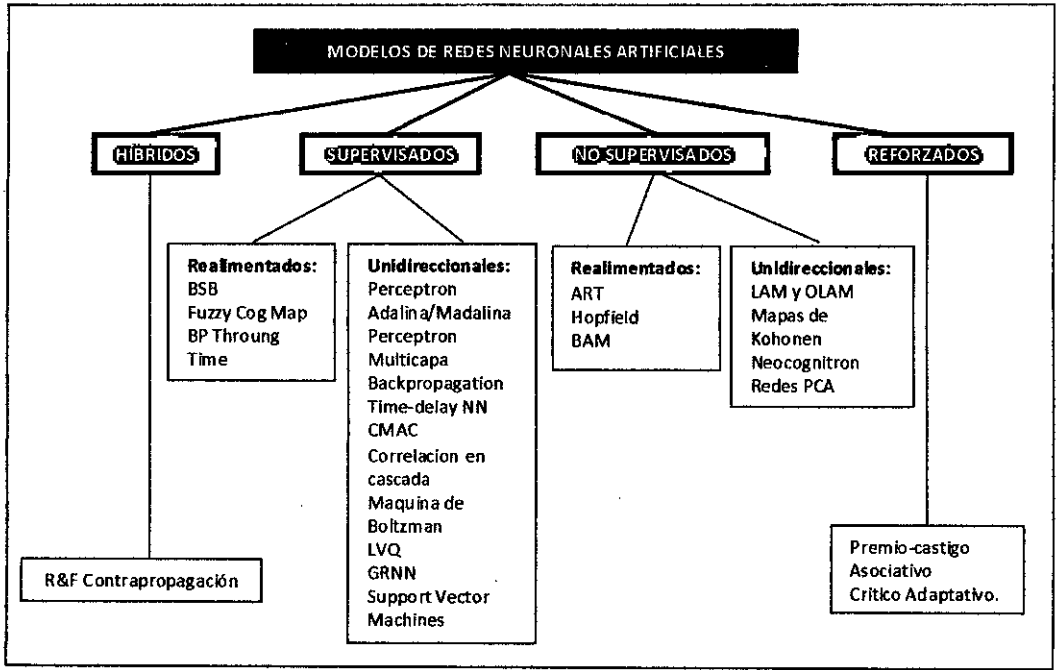
La Figura 2.5 muestra cada uno de los componentes en un proceso de procesamiento de información.



**Figura 2.5** Componentes para el procesamiento de información en una RNA.  
**Fuente:** Elaboración propia según [Hilera+ 1995].

### 2.2.2.9. Topología de las Redes Neuronales Artificiales.

De forma similar a las redes biológicas, una RNA puede ser organizada en diferentes formas (topologías), es decir, las neuronas pueden ser interconectadas de diferentes maneras. La Figura 2.6 muestra la clasificación de las Redes Neuronales Artificiales de acuerdo a su topología de conexión y regla de aprendizaje.



**Figura 2.6** Clasificación de las Redes Neuronales Artificiales.  
 Fuente: [DEL BRIO & SANZ, 2001]

## **2.3. Series de Tiempo.**

### **2.3.1. Definición.**

Una serie de tiempo es una secuencia cronológica de observaciones de una variable en particular. Estas observaciones se registran a menudo en intervalos fijos de tiempo [Hanke+ 2009].

En general, las series de tiempo no se comportan como muestras aleatorias y se requieren de métodos especiales para su análisis. Las observaciones de una serie de tiempo generalmente están relacionadas unas con otras (autocorrelacionadas), lo cual genera patrones de variabilidad que pueden utilizarse para pronosticar valores futuros [Hanke+ 2009].

En términos formales, una serie de tiempo se define como una secuencia de vectores dependientes del tiempo transcurrido  $t$ :

$$\bar{Y}(t)$$

Donde  $t = 0, 1, 2, 3, \dots$

El tiempo generalmente se ve en términos de pasos de tiempo discretos, conduciendo a una instancia de  $x$  en cada punto de un intervalo de tiempo, generalmente de tamaño fijo [Dorffner 1996].

### **2.3.2. Descomposición de una serie de tiempo.**

Un enfoque para el análisis de los datos de las series de tiempo incluye un intento por identificar los componentes que influyen en cada uno de los factores de la serie. Este procedimiento de identificación se llama *descomposición*. Los métodos de descomposición se usan para pronósticos tanto de corto como de largo plazo.

El análisis de una serie de tiempo a través de la descomposición de sus componentes se realiza con la intención de descubrir patrones históricos que puedan ser útiles en la predicción. La serie de tiempo esta compuesta de los siguientes componentes:

- **Tendencia.** La tendencia es el componente que representa el crecimiento o declinación subyacente en una serie de tiempo. La tendencia se produce, por ejemplo, como resultado de la inflación, de cambios demográficos, de cambios tecnológicos o incrementos en la productividad. El componente de tendencia se denota por  $T$ .
- **Componente Cíclico.** Es una serie de fluctuaciones en forma de onda o ciclos de más de una año de duración. Las condiciones cambiantes de la economía generalmente genera ciclos. El componente cíclico se denota por  $C$ .

En la práctica, los ciclos son difíciles de identificar, de manera que con frecuencia se les considera como parte de una tendencia. En este caso el crecimiento o declinación general subyacente del componente de le denomina *tendencia-ciclo* y se denota como  $T$ . Se usa la notación del componente de tendencia porque con frecuencia es difícil separar el componente cíclico de la tendencia.

- **Componente estacional.** Los componentes estacionales se encuentran generalmente en datos trimestrales, mensuales o semanales. La variación estacional se refiere a un patrón de cambio más o menos estable que aparece anualmente y se repite un año tras otro. Los patrones estacionales ocurren por la influencia del tiempo climatológico o por acontecimientos relacionados con el calendario, como las vacaciones escolares y los días feriados nacionales.  $S$  representa al componente estacional.

- **Componente Irregular.** El componente irregular consiste en fluctuaciones impredecibles o aleatorias. Estas fluctuaciones son el resultado de incontables hechos que de forma individual tal vez no sean particularmente importantes, pero cuyos efectos combinados suelen ser considerables.  $I$  representa al componente irregular.

Para estudiar los componentes de una serie de tiempo, es necesario considerar cómo se relacionan los componentes con la serie original. Esta tarea se lleva a cabo especificando un modelo (relación matemática) que exprese la variable  $Y$  de la serie de tiempo en términos de los componentes  $T, C, S$  e  $I$ .

Es difícil trabajar con el componente cíclico de una serie de tiempo, debido a la complejidad de la medición y determinación de los ciclos a partir de datos históricos, tanto para su duración (medida en años) como para su magnitud (diferencia entre altas y bajas) cuyos valores están lejos de ser constantes. Esta falta de un patrón consistente de la onda hace que se dificulte la distinción entre los ciclos y las tendencias que evolucionan con suavidad. En consecuencia, para simplificar, supondremos que cualquier ciclo en los datos es parte de la tendencia. De manera que inicialmente consideraremos sólo tres componentes:  $T, S$  e  $I$ .

Los modelos más utilizados para descomponer una serie de tiempo son el aditivo y el multiplicativo. Ambos modelos se denominan algunas veces *modelos de componentes no observados*, puesto que, en la práctica, si bien observamos los valores de la serie de tiempo, no sucede lo mismo con los valores de los componentes.

#### **2.3.2.1. Modelo Aditivo.**

Este modelo asume que los componentes de la serie son independientes, es decir, la amplitud de la estacionalidad es independiente del nivel de la tendencia. Un aumento en el nivel de la tendencia no ocasiona un aumento en la amplitud estacional.



$$Y_t = T_t + S_t + I_t$$

Donde:

$Y_t$  = serie original

$T_t$  = componete de Tendencia

$S_t$  = componente Estacional

$I_t$  = componete Irregular

Los componentes están expresados en unidades. En este caso la serie desestacionalizada se obtiene como:

$$YD_t = Y_t - S_t = T_t + I_t$$

### 2.3.2.2. Modelo Multiplicativo.

Este modelo asume que los componentes están interrelacionados. Un aumento en el nivel de la tendencia ocasiona un aumento en la amplitud estacional. Los componentes estacional e irregular están expresados en porcentajes.

$$Y_t = T_t * S_t * I_t$$

En este modelo, la serie desestacionalizada se obtiene como:

$$YD_t = \frac{Y_t}{S_t} = T_t * I_t$$

La mayoría de las series de tiempo económicas siguen un modelo multiplicativo. En los casos en que la serie presenta valores negativos o ceros, el único modelo aplicable es el aditivo.

### 2.3.3. Pronósticos de series de tiempo.

#### 2.3.3.1. Método de Promedios Móviles.

La suposición implícita de este método es que las fluctuaciones de los valores pasados representan puntos de partida aleatorios de alguna estructura subyacente. Una vez identificada esta estructura, es posible proyectarla hacia el futuro para generar un pronóstico.

**Promedios simples.** En este método se toma una decisión para usar los primeros puntos de datos  $t$  como la parte de inicialización y la parte restante de puntos como la parte de prueba. Luego se promedia la parte de inicialización de los datos y se pronostica el siguiente periodo utilizando la siguiente ecuación:

$$\hat{Y}_{t+1} = \frac{1}{t} \sum_{i=1}^t Y_i$$

Cuando una nueva observación está disponible, el pronóstico del siguiente periodo, se calcula incluyendo la nueva observación y utilizando la siguiente ecuación:

$$\hat{Y}_{t+2} = \frac{t\hat{Y}_{t+1} + Y_{t+1}}{t + 1}$$

El método de promedios simples es una técnica adecuada cuando los factores que producen la serie de tiempo que se va a pronosticar se han estabilizado y el ambiente en el cual se encuentra la serie generalmente permanece sin cambios. Ejemplos de este tipo de series son: las ventas efectuadas como resultado de un nivel de esfuerzo constante de los vendedores; las ventas de un producto en su etapa de madurez de su ciclo de vida; y el número de citas semanales de un dentista, doctor o abogado cuyo número de clientes o pacientes es estable.

**Promedios móviles.** Utiliza el enfoque de considerar las observaciones más recientes. Conforme esté disponible una nueva observación, se calcula una nueva media sumando el valor más reciente y eliminando el valor más antiguo. Entonces se usa este promedio móvil para pronosticar el siguiente periodo. La siguiente ecuación se utiliza para calcular el pronóstico mediante el método de promedio móvil de orden  $k$ ,  $MA(k)$ :

$$\hat{Y}_{t+1} = \frac{Y_t + Y_{t-1} + \dots + Y_{t-k+1}}{k}$$

Donde:

$\hat{Y}_{t+1}$  = *valor pronosticado para el siguiente periodo*

$Y_t$  = *valor real en el periodo  $t$*

$k$  = *número de términos en el promedio móvil*

El promedio móvil para el periodo de tiempo  $t$  es la medida aritmética de las  $k$  observaciones más recientes. En un promedio móvil, se asignan pesos iguales a cada observación. Conforme está disponible, cada nuevo punto de datos se incluye en el promedio y el punto de datos más antiguo se descarta. El porcentaje de respuesta a los cambios en el patrón subyacente de datos depende del número de periodos  $k$  incluidos en el promedio móvil.

La técnica de promedio móvil maneja sólo los últimos  $k$  periodos de los datos conocidos; el número de puntos de datos en cada promedio no cambia conforme el tiempo avanza. El modelo de promedio móvil no maneja muy bien la tendencia o estacionalidad, sin embargo, lo hace mejor que el método de promedio simple.

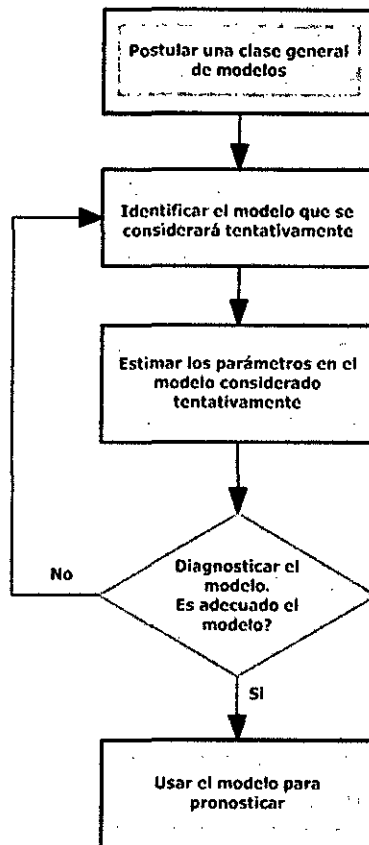
### 2.3.3.2. Metodología Box-Jenkins (ARIMA)

Box y Jenkins (1978) propusieron un modelo novedoso para la predicción de series de tiempo. Popularmente es conocida como metodología Box-Jenkins aunque técnicamente se conoce como metodología ARIMA, en la que se analizan las propiedades probabilísticas o estocásticas de las series de tiempo económicas bajo la filosofía de "permitir que la información hable por sí misma".

Los modelos autor regresivos integrados de promedio móvil (ARIMA) son una clase de modelos lineales que son capaces de representar tanto series de tiempo *estacionarias* como *no estacionarias*. Recuerde que los procesos estacionarios varían alrededor de un nivel fijo, en tanto que los procesos no estacionarios carecen de un nivel promedio constante natural.

La *metodología Box-Jenkins* para generar pronósticos es diferente de la mayoría de los métodos porque no supone ningún patrón particular en los datos históricos de las series que se van a pronosticar. Se basa en un enfoque iterativo para identificar un modelo posible a partir de una clase general de modelos. Luego, el modelo seleccionado se coteja con los datos históricos para ver si describe la serie con exactitud. El modelo está bien ajustado si los residuos son generalmente pequeños, están distribuidos aleatoriamente y no contienen información útil. Si el modelo especificado no es estacionario, el proceso se repite usando un nuevo modelo diseñado para mejorar el original. Este procedimiento iterativo continúa hasta que se encuentra un modelo satisfactorio. En ese momento el modelo se considera útil para pronosticar.

La Figura 2.7 ilustra la estrategia de construcción de un modelo Box-Jenkins.



**Figura 2.7** Diagrama de flujo para la construcción de un modelo Box-Jenkins.  
Fuente: [Hanke+ 2009].

La selección inicial de un modelo ARIMA se basa en examinar una gráfica de la serie de tiempo (para observar su carácter general) y en analizar sus autocorrelaciones para varios retrasos de tiempo. Específicamente, el patrón de las autocorrelaciones muestrales calculado a partir de la serie de tiempo se coteja con el patrón conocido de autocorrelación asociado con un modelo ARIMA particular.

Al seleccionar un modelo, las autocorrelaciones calculadas de los datos no serán exactamente iguales a las autocorrelaciones teóricas asociadas con un modelo ARIMA. Las autocorrelaciones calculadas de los datos están sujetas a la variación de la muestra, sin embargo, se debe igualar adecuadamente la mayoría de los datos de la serie de tiempo con un modelo ARIMA. Si la selección inicial no es totalmente correcta, se presentarán

deficiencias en el análisis de los residuos (verificación del modelo), y el modelo original podrá modificarse. Conforme se adquiere experiencia, esta tarea iterativa de construcción de modelos se hará mucho más fácil.

### **Proceso autorregresivo (AR).**

En el proceso autorregresivo de orden  $p$  la observación actual  $Y_t$  es generada por un promedio ponderado de observaciones pasadas que se remontan  $p$  periodos, junto con una perturbación aleatoria en el periodo actual. Se denota este proceso como  $AR(p)$  y la ecuación que lo describe es:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

Donde:

$Y_t =$  variable de respuesta (dependiente) en el tiempo  $t$

$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p} =$  variables de respuesta de retrasos

$\phi_0, \phi_1, \dots, \phi_p =$  coeficientes a estimar

$\varepsilon_t =$  error en el tiempo  $t$

Nota: El coeficiente  $\phi_0$  está relacionado con la media del proceso  $\mu$ , mediante  $\phi_0 = \mu(1 - \phi_1 - \phi_2 - \dots - \phi_p)$ .

La ecuación anterior tiene la apariencia de un modelo de regresión con valores retrasados de la variable dependiente en las posiciones de la variable independiente, de aquí su nombre de 'autorregresivo'.

### **Proceso de media móvil (MA).**

En el proceso de media móvil de orden  $q$  cada observación  $Y_t$  es generada por un promedio ponderado de perturbaciones aleatorias que se remontan  $q$  periodos. Se denota este proceso como  $MA(q)$  y su ecuación respectiva es:

$$Y_t = \mu - \omega_1 \varepsilon_{t-1} - \omega_2 \varepsilon_{t-2} - \dots - \omega_q \varepsilon_{t-q} + \varepsilon_t$$

Donde:

$Y_t$  = variable de respuesta (dependiente) en el tiempo  $t$

$\mu$  = promedio constante en el proceso

$\omega_1, \omega_2, \dots, \omega_q$  = variables de respuesta de retrasos

$\varepsilon_t$  = error en el tiempo  $t$

$\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$  = errores en periodos anteriores

Esta ecuación es muy similar a la ecuación mostrada para el proceso autorregresivo, excepto que la variable dependiente  $Y_t$ , depende de los valores anteriores de los errores y no de los valores de la variable misma. Los modelos de promedio móvil (MA) permiten hacer pronósticos de  $Y_t$  con base en una combinación lineal de un número finito de errores pasados, mientras que los modelos autorregresivos (AR) pronostican  $Y_t$  como una función lineal de un número finito de valores pasados de  $Y_t$ .

El término *promedio móvil* para el modelado de la ecuación mostrada es histórico y no debe confundirse con los otros procedimientos de promedio móvil mostrados anteriormente para el pronóstico de series de tiempo. Aquí, el *promedio móvil* se refiere al hecho de que la desviación de la respuesta de su media  $Y_t - \mu$ , es una combinación lineal de los errores actuales y pasados que, conforme el tiempo avanza, los errores implicados en esta combinación también se mueven hacia adelante.

$$Y_t - \mu = \varepsilon_t - \omega_1 \varepsilon_{t-1} - \omega_2 \varepsilon_{t-2} - \dots - \omega_q \varepsilon_{t-q}$$

$$Y_{t+1} - \mu = \varepsilon_{t+1} - \omega_1 \varepsilon_t - \omega_2 \varepsilon_{t-1} - \dots - \omega_q \varepsilon_{t-q+1}$$

Los pesos  $\omega_1, \omega_2, \dots, \omega_q$ , no necesariamente suman 1 y pueden ser positivos o negativos, aun cuando estén precedidos de un signo negativo en la especificación del modelo.

Además, las series de tiempo económicas generalmente no son estacionarias, es decir, son integradas, razón por la cual si agregamos el concepto de integración explicado anteriormente, de manera que se tenga que diferenciar una serie de tiempo  $d$  veces para hacerla estacionaria y luego aplicar a esta el modelo  $RMA(p, q)$  se dice que la serie de tiempo original es del tipo  $ARIMA(p, d, q)$ , es decir, es una serie de tiempo autorregresiva *integrada* de media móvil.

Los modelos de series no estacionarias se llaman modelos de promedio móvil integrados autorregresivos y se denotan por  $ARIMA(p, d, q)$ . Aquí,  $p$  indica el orden de la parte autorregresiva,  $d$  indica el número de diferenciaciones, y  $q$  indica el orden de la parte de promedio móvil. Si la serie original es estacionaria, entonces  $d = 0$  y los modelos  $ARIMA$  se reducen a modelos  $ARMA$ . Por consiguiente, la notación  $ARIMA(p, d, q)$  se usa para identificar tanto series estacionarias ( $d = 0$ ) como no estacionarias ( $d > 0$ ).

## **2.4. Redes Neuronales Artificiales en el pronóstico financiero.**

Las Redes Neuronales Artificiales han sido ampliamente utilizadas para predecir diversos índices de precios en los mercados de valores debido a sus capacidades de trabajar con datos no lineales, además poseen la capacidad de auto-aprendizaje [Smith+ 2002]. Así, en muchas situaciones de toma de decisiones financieras, las Redes Neuronales Artificiales actúan como sistemas suplementarios y muchas veces reemplazan a sistemas estadísticos convencionales debido a que proveen ventajas en sus características y rendimiento que no están disponibles en sistemas tradicionales [Trippi+ 1996].

Según estudios realizados [Wong+ 2000], más de cincuenta por ciento de los estudios sobre Redes Neuronales Artificiales aplicado a los

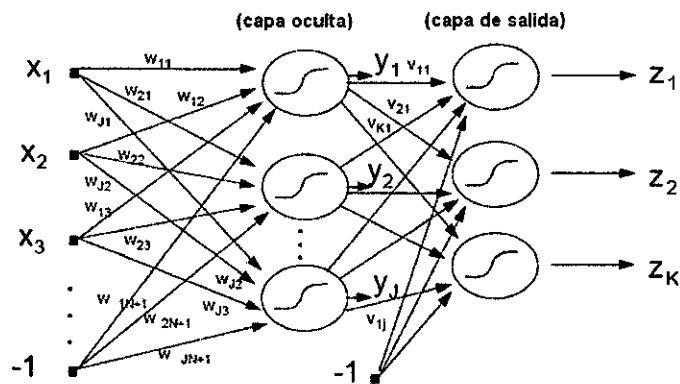


negocios, utilizan Redes Neuronales Artificiales Multicapa de tipo Supervisada (MPL, Multilayer Perceptron). Este tipo de red neuronal es muy popular debido a su amplia aplicabilidad a los dominios de problema de gran importancia para los negocios: los principales son la predicción, clasificación y modelado.

Las MLPs son apropiadas para resolver problemas que implican el aprendizaje de las relaciones entre un conjunto de entradas y salidas conocidas. Se trata de una técnica de aprendizaje supervisado, en el sentido de que requieren un conjunto de datos de entrenamiento para aprender las relaciones [Smith+ 2002].

### 2.4.1. Arquitectura de las Redes Neuronales Artificiales de tipo MLP.

La arquitectura de una red de tipo MPL (Perceptrón Multicapa) se muestra en la Figura 2.8 y consta de una capa de entrada, una capa de salida, y al menos una capa de neuronas ocultas entre las capas de entrada y la de salida. El flujo de información es de izquierda a derecha, con entradas  $x$  que pasan a través de la red vía conexiones con pesos asignados hacia la capa oculta de neuronas  $y$ , posteriormente, a la capa de salida. Los pesos que conectan los elementos de entrada  $i$  con la neurona oculta  $j$  se denotan por  $W_{ji}$ , mientras que los pesos que conectan ;a neurona oculta  $j$  con la neurona de salida  $k$  se denotan por  $V_{kj}$ .



**Figura 2.8** Arquitectura de una red de tipo MFNN.

Fuente: [Smith+ 2002]

Cada neurona calcula su salida basada en número de entradas que recibe. Las entradas se calculan con una función sumatoria del valor de los elementos con su respectivo peso asignado, mientras que la salida se calcula mediante la función sigmoideal y depende de la magnitud de las entradas.

Hay una serie de medidas de rendimiento que se utilizan comúnmente para indicar qué tan bien una Red Neuronal Artificial ha aprendido de las relaciones entre los datos [Smith+ 2002]. Para los problemas de predicción, estas medidas se refieren normalmente a los errores entre los resultados previstos y los resultados reales.

La Tabla 2.2 muestra algunas de las medidas de rendimiento más comunes para problemas de predicción. Los tres primeros forman la familia de los errores cuadráticos medios: el error cuadrático medio estándar (MSE), la raíz del error cuadrático medio (RMSE), y el error cuadrático medio normalizado (NMSE).

Los errores se elevan al cuadrado para penalizar más los errores y para cancelar el efecto de los valores positivos y negativos de las diferencias.  $R^2$  es el coeficiente de determinación y se relaciona con el NMSE desde  $NMSE = 1 - R^2$ .

Un valor  $R^2$  de 1 indica un ajuste perfecto de los datos, mientras que un valor de 0 indica que el rendimiento que se puede esperar de utilizar el valor promedio de la actual salida  $d$  como base de todas las predicciones. Las siguientes dos medidas utilizan el error absoluto (en lugar del error al cuadrático): el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE). Otras medidas, como el error absoluto máximo también se utilizan para indicar el rendimiento peor de los casos de rendimiento del modelo.

**Tabla 2.2** Medidas de Rendimiento Común para Predicciones

Fuente: [Smith+ 2002]

Error Cuadrático Medio (MSE)	$\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2$
Raíz del Error Cuadrático Medio (RMSE)	$\sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2}$
Error Absoluto Medio (MAE)	$\frac{1}{n} \sum_{t=1}^n  Y_t - \hat{Y}_t $
Error Porcentual Medio (MPE)	$100\% \times \frac{1}{n} \sum_{t=1}^n \frac{(Y_t - \hat{Y}_t)}{Y_t}$
Error Porcentual Absoluto Medio (MAPE)	$100\% \times \frac{1}{n} \sum_{t=1}^n \frac{ Y_t - \hat{Y}_t }{ Y_t }$

## **CAPÍTULO III**

### **MODELO PROPUESTO**

#### **3.1. Justificación del modelo propuesto.**

Si bien, se ha utilizado con relativo éxito diversas técnicas y métodos en el pronóstico de precios de acciones, éstas se han limitado al uso de modelos estadísticos tradicionales [Trejos+, 2003], destacando ampliamente el uso de la metodología Box-Jenkins, sin embargo, a la fecha se han desarrollado una serie de técnicas no tradicionales basados principalmente en el uso de técnicas de Inteligencia Artificial.

En la actualidad, no se tiene conocimiento de la aplicación de técnicas de Inteligencia Artificial en el pronóstico de series de tiempo en la Bolsa de Valores de Lima. Las propuestas en este campo se han limitado al desarrollo de modelos para encontrar patrones de comportamiento en otros sectores e industrias [Quispe+ 2002], por lo que este trabajo de investigación pretende determinar la factibilidad del uso de Redes Neuronales Artificiales en el pronóstico de indicadores financieros en el mercado de valores del Perú y ser un investigación novedosa.


### **3.2.Descripción del modelo propuesto**

El modelo propuesto para nuestra investigación estará conformado por una Red Neuronal Artificial de Supervisada, dado que se cuenta con un conjunto de datos de entrada de las cuales conocemos su respectivo valor de salida. Se utilizará el algoritmo de retropropagación para ajustar los respectivos parámetros de la red, esto es, el entrenamiento de la red. El número de capas ocultas y el número de neuronas en cada una de las capas se irá modificando iterativamente durante el experimento hasta llegar a la arquitectura que mejores resultados obtenga comparado con los resultados obtenidos con la metodología tradicional Box-Jenkins (ARIMA).

El motivo de la arquitectura propuesta radica en hecho que investigaciones previas han demostrado la efectividad de este tipo de redes en el pronóstico de series de tiempo de tipo financieras [Smith+ 2002].

### **3.3.Arquitectura del modelo propuesto**

El modelo de red neuronal propuesto estará compuesto de una capa de entrada conformada por 'n' neuronas, una o dos capas ocultas con 'm' neuronas y una única capa de salida que tendrá el valor final del pronóstico. El método de entrenamiento será implementado a través del algoritmo de retropropagación y la función de activación lo constituirá la función sigmoideal. La Figura muestra la arquitectura propuesta para nuestro modelo.

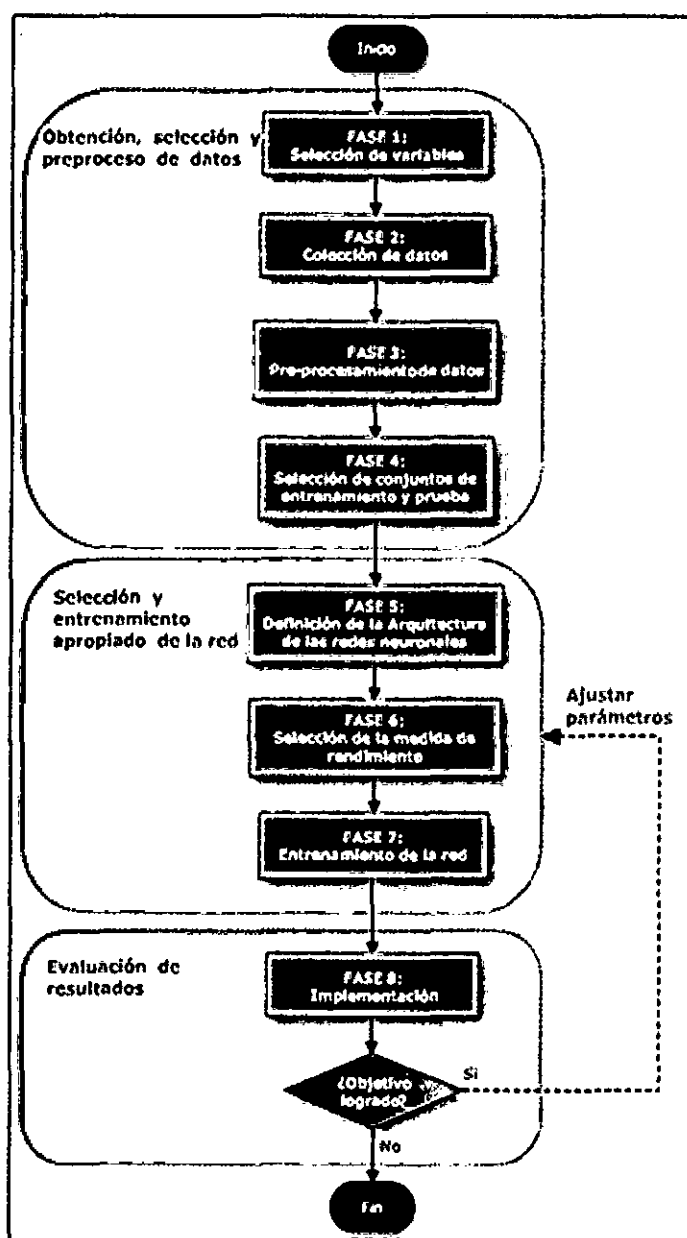


**Figura 3.1** Arquitectura de la RNA propuesta.

**Fuente:** Elaboración propia

### 3.4. Construcción del Modelo de Redes Neuronales Artificiales

Para la construcción del modelo de Redes Neuronales Artificiales propuesto en esta investigación se seguirá la metodología propuesta por Kaastra y Boyd [Kaastra+ 1996] para el diseño de modelos de redes neuronales aplicados a predicciones de series de tiempo financieras y económicas, la cual está compuesta por ocho pasos mostrados en la Figura 3.2 y descritos a continuación.



**Figura 3.2 Metodología para la construcción de un modelo de RNA.**

**Fuente:** Elaboración propia según [Kaastra+ 1996]

### 3.4.1. FASE 1: Selección de variables

En esta fase, seleccionamos las variables que influyen significativamente en la predicción del precio de acciones en la BVL. Generalmente, en las

aplicaciones en mercados accionarios y de derivados es más probable el uso de datos diarios en el diseño de una red neuronal [Kaastra+ 1996].

Las típicas variables involucradas en la predicción de series de tiempo financieras son:

$Y_o$ : precio de apertura de la acción por día

$Y_c$ : precio de cierre de la acción por día

$Y_h$ : precio máximo de la acción por día

$Y_l$ : precio mínimo de la acción por día

Para nuestro caso particular realizaremos el precio de cierre  $Y_c$ , debido a que este es el precio que los analistas bursátiles utilizan para tomar sus decisiones de inversión.

### **3.4.2. FASE 2: Colección de datos**

Se refiere al proceso de obtención de los datos históricos que representan a las variables seleccionadas en la fase anterior. Los datos lo encontramos en las diversas fuentes de datos e información histórica proporcionadas por la Bolsa de Valores de Lima (BVL) y la Comisión Nacional Supervisora de Empresas y Valores (CONASEV).

Para nuestro estudio se ha considerado información del precio diarios de las acciones en el periodo comprendido entre los años 2007 y 2011 (5 años).

### **3.4.3. FASE 3: Pre-procesamiento de datos**

El pre-procesamiento de datos se refiere al hecho de analizar y transformar las variables de entrada y salida para minimizar el ruido, enfatizar relaciones



importantes, detectar tendencias, y “suavizar” la distribución de la variable para ayudar a la red neuronal en el aprendizaje de patrones relevantes. Como las redes neuronales son buscadores de patrones, la representación de los datos es crítica en el diseño de una red exitosa.

Una buena estrategia es escalar los datos entre los límites inferior y superior de la función de transferencia (generalmente entre 0 y 1 ó -1 y 1).

En nuestro estudio, “suavizaremos” los datos de entrada dividiendo su valor entre 100 para obtener los nuevos valores en el rango de 0 y 1. La salida tendrá que ser “des-suavizada” utilizando el proceso inverso, en este caso, tendremos que multiplicarlo por 100.

#### **3.4.4. FASE 4: Selección de conjuntos de entrenamiento y prueba**

Comúnmente el total de datos de la muestra se divide en dos conjuntos, llamados de entrenamiento y prueba. El conjunto de entrenamiento es el más grande y es utilizado por la red neuronal para aprender los patrones existentes en los datos. El conjunto de prueba, que varía del 10% al 30% del conjunto de entrenamiento, se utiliza para evaluar la capacidad de generalización de una red ya entrenada.

Para nuestro estudio se ha considerado información del precio de las acciones en el periodo comprendido entre los años 2007 y Junio del 2012 (5.5 años), de los cuales aproximadamente el 90% (5 años) será utilizado para el entrenamiento y el 10% (1/2 año) restante para la verificación de los resultados y nivel de aproximación del pronóstico de nuestro modelo.

Para definir los conjuntos de entrenamiento y prueba, organizaremos la serie de tiempo en un conjunto de datos bidimensional en donde cada fila será un conjunto. Por ejemplo, si suponemos que la salida  $Y$  de la red depende de cinco entradas  $(X_1, X_2, X_3, X_4, X_5)$ , tendremos los siguientes conjuntos de entrenamiento:

**Tabla 3.1** Ejemplo de formación de conjuntos de entrenamiento

*Fuente:* Elaboración propia

Conjunto	$X_1$	$X_2$	$X_3$	$X_4$	$X_5$	$Y$
1	$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$	$Y_6$
2	$Y_2$	$Y_3$	$Y_4$	$Y_5$	$Y_6$	$Y_7$
3	$Y_3$	$Y_4$	$Y_5$	$Y_6$	$Y_7$	$Y_8$
4	$Y_4$	$Y_5$	$Y_6$	$Y_7$	$Y_8$	$Y_9$
.	.	.	.	.	.	.
t-5	$Y_{t-5}$	$Y_{t-4}$	$Y_{t-3}$	$Y_{t-2}$	$Y_{t-1}$	$Y_t$

### 3.4.5. FASE 5: Definición de la arquitectura

Como ya se mencionó, en esta investigación utilizaremos el modelo de Redes Neuronales Artificiales Multicapa de tipo Supervisada (MLP, Multilayer Perceptron).

Sin embargo es necesario definir una serie de características para establecer la arquitectura del Modelo de Red Neuronal Artificial:

- **Número de capas ocultas.**

Las capas ocultas dan a la red la habilidad de generalizar, y en la práctica las redes neuronales con una ó dos capas ocultas son las más utilizadas y han tenido un buen desempeño. El incremento en el número de capas también incrementa el tiempo de procesamiento y el peligro de sobreajuste lo que conduce a un pobre desempeño en la predicción fuera de muestra.

En esta investigación se empleará una sola capa oculta, ya que una capa es suficiente, de acuerdo a lo mencionado en el marco teórico para aproximar cualquier función razonable.

- **Número de neuronas ocultas**

Para determinar el número de neuronas en la capa oculta no existen reglas generales o teorías, aunque existen algunas recomendaciones sugeridas por varios investigadores:

- Shih [Shih 2001], sugiere que la topología de la red debe tener una forma piramidal, esto es, tener el mayor número de neuronas en la capa de entrada y menos en las posteriores. Recomienda que el número de neuronas en cada capa este más o menos entre la mitad de la capa siguiente y el doble del número de la capa anterior.

- Azoff [Azoff 1994], son suficientes  $2N+1$  neuronas para  $N$  entradas.

De acuerdo a Panchal, Ganatra y Kosta [Panchal+ 2011], lo recomendable es empezar a probar con un número pequeño de neuronas ocultas e ir incrementando gradualmente hasta encontrar el número adecuado de neuronas ocultas. De esta forma, el problema del sobreajuste que puede ocurrir al existir más pesos (parámetros) que muestras de datos puede ser reducido. Este es el método que se empleará para determinar el número de neuronas en la capa oculta de nuestra red propuesta.

- **Número de neuronas de salida**

Para nuestro caso se utilizará una única neurona de salida. Cabe mencionar que las redes neuronales con múltiples salidas, especialmente si éstas salidas están ampliamente espaciadas, producirán resultados inferiores en comparación con una red con una única salida.

- **Funciones de transferencia**

Levich y Thomas (1993) y Kao y Ma (1992) encontraron que los mercados financieros son no lineales y tienen memoria, sugiriendo que las funciones de transferencia no lineales son las más apropiadas. Las funciones de transferencia sigmoideas se utilizan comúnmente para datos de series de tiempo porque son no lineales y continuamente diferenciables, propiedades que son deseables para el entrenamiento de nuestro modelo de red propuesto.

### **3.4.6. FASE 6: Selección de la medida de rendimiento.**

Hay una serie de medidas de rendimiento que se utilizan comúnmente para indicar qué tan bien una Red Neuronal Artificial ha aprendido de las relaciones entre los datos [Smith+ 2002]. Para los problemas de predicción, estas medidas se refieren normalmente a los errores entre los resultados previstos y los resultados reales. Algunas de las medidas de rendimiento más comunes para problemas de predicción son: el error cuadrático medio estándar (MSE), la raíz del error cuadrático medio (RMSE), y el error cuadrático medio normalizado (NMSE).

Para nuestro estudio utilizaremos la función del error cuadrático medio estándar (MSE). En este método, cada error o residuo se eleva al cuadrado; luego éstos se suman y se dividen entre el número de observaciones. Este enfoque penaliza errores grandes en la elaboración de pronósticos, ya que los errores están elevados al cuadrado, lo cual es importante porque una técnica que produce errores moderados quizá sea preferible a una que usualmente tenga errores pequeños, pero ocasionalmente produce errores extremadamente grandes [Hanke+ 2009]. El MSE se calcula con la siguiente ecuación:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2$$

$Y_t =$  Valor de una serie de tiempo en el periodo  $t$

$\hat{Y}_t =$  Valor pronosticado de  $Y_t$

$e_t = Y_t - \hat{Y}_t =$  Residuo o error de pronóstico

### 3.4.7. FASE 7: Entrenamiento de la red.

Entrenar una red neuronal para aprender patrones involucra el presentarle ejemplos de manera iterativa de las respuestas correctas. El objetivo del entrenamiento es encontrar un conjunto de pesos entre las neuronas que determinan el mínimo global de la función de error.

Para el entrenamiento de nuestro modelo de red se utilizará el algoritmo de retropropagación.

- **Algoritmo de Retropropagación.**

El algoritmo de retropropagación se puede describir a través de los siguientes pasos:

Paso 1: Seleccionar aleatoriamente un patrón de entrada  $x$  a ser ingresado a la red MLP mediante la capa de entrada.

Paso 2: Calcular las entradas y salidas de las neuronas de la capa oculta.

$$net_j^h = \sum_{i=1}^{N+1} w_{ij}x_i \quad y_j = f(net_j^h)$$

Paso 3: Calcular las entradas y salidas de la capa de neuronas de salida.

$$net_k^o = \sum_{j=1}^{J+1} v_{kj}y_j \quad z_k = f(net_k^o)$$

Paso 4: Actualización de los pesos en la capa de salida.

$$v_{kj} \leftarrow v_{kj} + c\lambda(d_k - z_k)z_k(1 - z_k)y_j$$

Paso 5: Actualización de los pesos en la capa oculta.

$$w_{ji} \leftarrow w_{ji} + c\lambda^2 y_j(1 - y_j)x_i \left( \sum_{k=1}^K (d_k - z_k)z_k(1 - z_k)v_{kj} \right)$$

Paso 6: Actualizar el error.

$$E \leftarrow E + \sum_{k=1}^K (d_k - z_k)^2$$

Repetir desde el paso 1 para todas las entradas que se han presentado.

Paso 7: Se detiene si E está por debajo de cierto nivel de tolerancia predefinidas (por ejemplo 0,000001). De lo contrario, restablecer E = 0, y repita desde el paso 1.

### 3.4.8. FASE 8: Implementación.

Para nuestro estudio, realizaremos la implementación del sistema utilizando el paradigma de Orientación a Objetos, para lo cual utilizaremos el lenguaje de programación Java.

Cabe mencionar la necesidad de re-entrenar la red periódicamente para que no pierda su habilidad de adaptación. Una vez implementada, el desempeño de la red se degradará con el tiempo, sin embargo, aún cuando se realice un entrenamiento periódico, no se garantiza el desempeño de la red porque se puede dar el caso de que las variables independientes seleccionadas cambien de importancia.

## **CAPÍTULO IV**

### **UN SISTEMA DE PRONÓSTICO DE PRECIOS DE ACCIONES**

En este capítulo se describe el sistema a construir, el cual implementa los distintos algoritmos utilizados en nuestro modelo de Redes Neuronales Artificiales.

#### **4.1. Descripción del Sistema**

El sistema ha sido construido utilizando la metodología RUP como proceso de desarrollo de software evolutivo e incremental. El modelo incremental nos permite combinar elementos del modelo lineal secuencial tradicional aplicados de manera repetitiva, lo que ha permitido el desarrollo exitoso de sistemas de información complejos [Kruchten 2000].

Se utilizó el lenguaje de programación JAVA para la implementación del modelo de Redes Neuronales Artificiales propuesto, debido a su portabilidad, su facilidad de interconexión con otras plataformas y a sus características de implementación del paradigma Orientado a Objetos [Eeles+, 2002].

## 4.2.Requerimientos del Sistema

A continuación se describen cada una de las características, necesidades y restricciones que el sistema a implementar debe cumplir.

### Lista de características

**Tabla 4.1** Características del sistema

*Fuente:* Elaboración propia.

<b>FEAT 1.</b>	El sistema deberá implementar u mecanismo de ingreso de datos para la lectura de información histórica de la variable a pronosticar.
<b>FEAT 2.</b>	El sistema deberá permitir elegir el precio de la acción a pronosticar: Apertura, Máximo, Mínimo o Cierre.
<b>FEAT 3.</b>	El sistema deberá permitir elegir la cantidad de datos para el entrenamiento y la cantidad de datos de prueba.
<b>FEAT 4.</b>	El sistema deberá permitir elegir la cantidad de neuronas en la capa de entrada del modelo de red.
<b>FEAT 5.</b>	El sistema deberá permitir elegir la cantidad de neuronas en la capa oculta del modelo de red.
<b>FEAT 6.</b>	El sistema deberá permitir elegir la cantidad de neuronas en la capa de salida del modelo de red.
<b>FEAT 7.</b>	El sistema deberá permitir elegir el algoritmo de entrenamiento del modelo de red.
<b>FEAT 8</b>	El sistema deberá permitir establecer la cantidad interacciones y error máximos permitidos para la fase de entrenamiento.
<b>FEAT 9.</b>	El sistema deberá permitir elegir la función de activación en cada una de las neuronas del modelo de red.



<b>FEAT 10.</b>	El sistema deberá tener una sección para visualizar los datos reales y los pronosticados. Además deberá calcular los distintos indicadores de performance del pronóstico.
<b>FEAT 11.</b>	El sistema deberá permitir visualizar de forma grafica el resultado obtenido para el periodo de pronóstico a través de un grafico de comportamiento diario de la variable pronosticada.

#### 4.2.1. Especificaciones Suplementarias.

Se refiere a las características de Usabilidad, Confiabilidad, Performance y Seguridad que el sistema debe cumplir.

**Tabla 4.2** Especificaciones Suplementarias del Sistema.

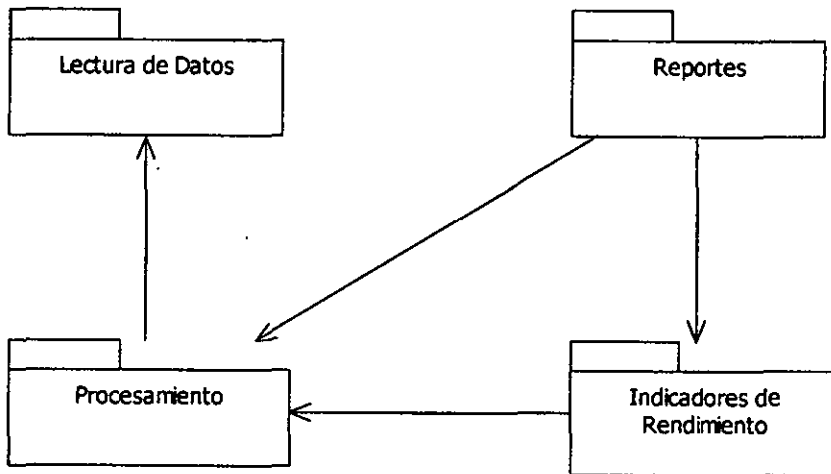
*Fuente:* Elaboración propia

<b>SUPL 1</b>	Lenguaje de Programación	El sistema deberá ser construido utilizando el paradigma Orientado a Objetos implementado mediante el lenguaje de programación Java 1.5.
<b>SUPL 2</b>	Reportes	El sistema debe permitir la exportación de los resultados a Hoja de Cálculo con formato Microsoft Excel 2003 o superior, además los reportes gráficos deberán ser construidos mediante la librería freeChart 1.0.0.
<b>SUPL 3</b>	Validación de datos	El sistema validara la información que se va a utilizar en el modelo, para ello visualizara un mensaje de error cuando la data no esté estructurada de manera adecuada.
<b>SUPL 4</b>	Cancelación de operaciones	El sistema permitirá la cancelación de cualquier operación generada vía la implementación de la funcionalidad (Botón cancelar en las interfaces de usuario).

<b>SUPL 5</b>	Plataformas	El sistema será multiplataforma y compatible con versiones de Windows y Linux.
<b>SUPL 6</b>	Configuración	El sistema permitirá configurar los parámetros del sistema de manera sencilla.

#### 4.2.2. Modelo de Casos de Uso

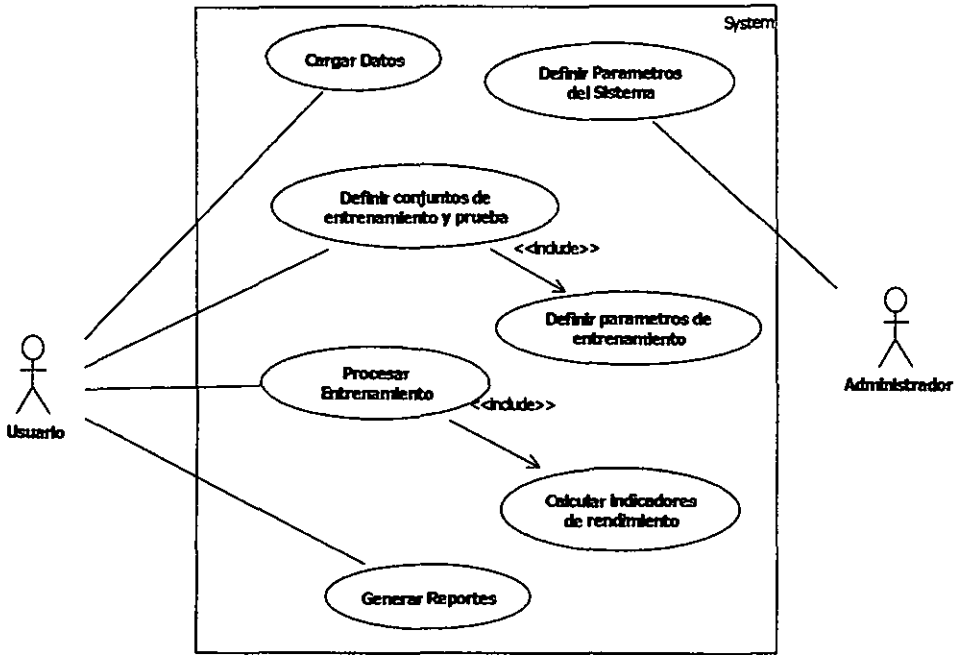
##### Diagrama de Paquetes



**Figura 4.1** Diagrama de Paquetes del Sistema

Fuente: Elaboración propia

## Diagrama de Casos de Uso



**Figura 4.2** Diagrama de Casos de Uso del Sistema

Fuente: Elaboración propia

### 4.2.3. Especificación de Casos de Uso.

A continuación se describe cada uno de los casos de uso identificados, de acuerdo a la metodología RUP establecida.

**Tabla 4.3** Especificación de Caso del Uso: Cargar datos.

<b>Nombre del Caso de Uso #1</b>	Cargar datos
<b>Descripción</b>	
Este Caso de Uso permite definir los datos de las series de tiempo como entrada en el sistema. Los datos históricos están compuestos por los datos de entrenamiento y prueba.	
<b>Actor(es)</b>	
Usuario del sistema	
<b>Pre-condiciones</b>	

-El archivo tiene la estructura establecida y está en formato *.csv.	
<b>Post-condiciones</b>	
-El Sistema ha cargado la información del precio de la acción y está disponible para realizar el entrenamiento.	
<b>Flujo de Eventos</b>	
<b>Flujo Básico</b>	
1. El usuario inicia el sistema, escoge la variable a pronosticar (tipo de precio) y hace click en el botón "...” para proceder a buscar el archivo *.csv que contiene los datos históricos de la serie de tiempo.	2. El sistema muestra una pantalla para que el usuario escoja y/o busque el archivo con los datos que desea utilizar en el pronóstico.
3. El usuario selecciona el archivo y presiona el botón "Aceptar".	4. El sistema realiza la lectura del archivo, no sin antes validar la estructura, si el archivo presenta algún error, el sistema informa vía un log en la pantalla.
<b>Referencias</b>	
Características: FEAT 2, FEAT 2 y SUPL 3.	

**Tabla 4.4** Especificación de Caso de Uso: Definir conjuntos de entrenamiento y prueba.

<b>1. Nombre del Caso de Uso #2</b>	Definir conjuntos de entrenamiento y prueba.
<b>2. Descripción</b>	
Este Caso de Uso permite seleccionar las fechas de inicio de los conjuntos de entrenamiento y prueba para la serie de tiempo dada.	
<b>3. Actor(es)</b>	
Usuario del sistema	
<b>4. Pre-condiciones</b>	
-El Sistema tiene cargada la información del precio de la acción.	
<b>5. Post-condiciones</b>	
-El Sistema ha definido el inicio de las fechas de los conjuntos de entrenamiento y pruebas.	
<b>6. Flujo de Eventos</b>	
<b>7. Flujo Básico</b>	
1. El usuario escoge las fechas de inicio para los conjuntos de entrenamiento y prueba: -Data de Entrenamiento (desde) -Data de Prueba (desde)	2. El sistema define las fechas de inicio para los conjuntos de entrenamiento y prueba. El sistema valida que la fecha de inicio del conjunto de pruebas sea mayor a la fecha de inicio del conjunto de entrenamiento.

<b>8. Referencias</b>
Características: FEAT 3.

**Tabla 4.5** Especificación de Caso de Uso: Definir parámetros de entrenamiento.

<b>1. Nombre del Caso de Uso #3</b>	Definir parámetros de entrenamiento.
<b>2. Descripción</b>	
Este Caso de Uso permite definir los parámetros necesarios para realizar un proceso de entrenamiento.	
<b>3. Actor(es)</b>	
Usuario del sistema	
<b>4. Pre-condiciones</b>	
-El Sistema tiene cargada la información del precio de la acción.	
<b>5. Post-condiciones</b>	
-El Sistema ha definido los parámetros para comenzar el proceso de entrenamiento.	
<b>6. Flujo de Eventos</b>	
<b>7. Flujo Básico</b>	
1. El usuario escoge los parámetros del sistema: -Error Máximo Permitido -Iteraciones Máximas (épocas) -Algoritmo de Entrenamiento	2. El sistema define guarda los parámetros para su utilización en el proceso de entrenamiento.
<b>8. Referencias</b>	
Características: FEAT 7, FEAT 8 y FEAT 9.	

**Tabla 4.6** Especificación de Caso de Uso: Procesar entrenamiento.

<b>1. Nombre del Caso de Uso #4</b>	Procesar entrenamiento.
<b>2. Descripción</b>	
Este Caso de Uso permite procesar el entrenamiento de la red.	
<b>3. Actor(es)</b>	
Usuario del sistema	
<b>4. Pre-condiciones</b>	
-El Sistema tiene cargada la información del precio de la acción. -El Sistema tiene definido los parámetros de entrenamiento. -El Sistema tiene definido los conjuntos de entrenamiento y prueba.	
<b>5. Post-condiciones</b>	
-El Sistema ha entrenado la Red con los parámetros definidos y se encuentra listo para ejecutar el pronóstico y comprobar con el conjunto de pruebas.	
<b>6. Flujo de Eventos</b>	
<b>7. Flujo Básico</b>	

<p>1. El usuario define la Topología de la Red, para ello define la cantidad de neuronas a utilizar en las diferentes capas de la Red:</p> <p>#Neuronas en la capa de Entrada # Neuronas en la capa Oculta # Neuronas en la capa de Salida</p>	<p>2. El Sistema establece la Topología de la Red para ser utilizado en el procesamiento de los datos de series de tiempo. Pro defecto el Sistema definirá una arquitectura de 3 capas, con una única neurona en la capa de salida.</p>
<p>3. El usuario hace click en el botón "Ejecutar".</p>	<p>4. El Sistema comienza el procesamiento del entrenamiento del modelo de Red con los parámetros y el conjunto de datos de entrenamiento y pruebas. Por cada Iteración el sistema muestra un log del error de aproximación que se viene logrando.</p> <p>5. El Sistema llama al Caso de Uso #6.</p>
<p><b>8. Referencias</b></p>	
<p>Características: FEAT 4, FEAT 5 y FEAT 6.</p>	

**Tabla 4.7** Especificación de Caso de Uso: Calcular indicadores de rendimiento.

<b>1. Nombre del Caso de Uso #5</b>	Calcular indicadores de rendimiento.
<b>2. Descripción</b>	
Este Caso de Uso permite calcular los indicadores de rendimiento del Modelo de Red establecido.	
<b>3. Actor(es)</b>	
Usuario del sistema	
<b>4. Pre-condiciones</b>	
-El Sistema ha realizado el proceso de entrenamiento de la Red.	
<b>5. Post-condiciones</b>	
-El Sistema ha calculado los indicadores de rendimiento del Modelo de Red ejecutado.	
<b>6. Flujo de Eventos</b>	
<b>7. Flujo Básico</b>	
<p>1. El usuario hace click en el botón "Ver Resultados".</p>	<p>2. El sistema calcula los cuatro tipos de error para verificar el nivel de rendimiento alcanzado, los indicadores son:</p> <ul style="list-style-type: none"> <li>-Error Cuadrático Medio(MSE)</li> <li>-Raíz del Error cuadrático Medio (RMSE)</li> <li>-Error Porcentual Medio (MPE)</li> <li>-Error Porcentual Absoluto Medio (MAPE)</li> </ul>
<b>8. Referencias</b>	

Características: FEAT 10 y SUPL 2.

**Tabla 4.8** Especificación de Caso de Uso: Generar reportes.

<b>1. Nombre del Caso de Uso #6</b>	Generar reportes.
<b>2. Descripción</b>	
Este Caso de Uso permite calcular y visualizar el resultado del procesamiento de la Red.	
<b>3. Actor(es)</b>	
Usuario del sistema	
<b>4. Pre-condiciones</b>	
-El Sistema ha realizado las pruebas de rendimiento de la Red con los datos del conjunto de pruebas definido. -El Sistema ha calculado los indicadores de rendimiento del Modelo de Red ejecutado.	
<b>5. Post-condiciones</b>	
-El Sistema muestra un reporte grafico del pronóstico realizado para los datos del conjunto de pruebas.	
<b>6. Flujo de Eventos</b>	
<b>7. Flujo Básico</b>	
1. El usuario hace click en el botón "Ver Resultados".	2. El Sistema muestra en pantalla el valor Real y el Pronóstico, del precio de la acción en estudio, para el Modelo de Red establecido. 3. El Sistema muestra un grafico del comportamiento diario de los valores Real y Pronosticado, del precio de la acción en estudio, en el periodo del conjunto de datos de prueba establecido.
<b>8. Referencias</b>	
Características: FEAT 10 y FEAT 11.	

## 4.3. Diseño del Sistema

### 4.3.1. Modelo de Diseño

Para efectos de esta investigación se procedió a la identificación de cada una de las clases de diseño involucradas en la arquitectura del sistema. El modelo de diseño está representado por un Diagrama de Clases de Diseño.

# Diagrama de Clases de Diseño del Sistema

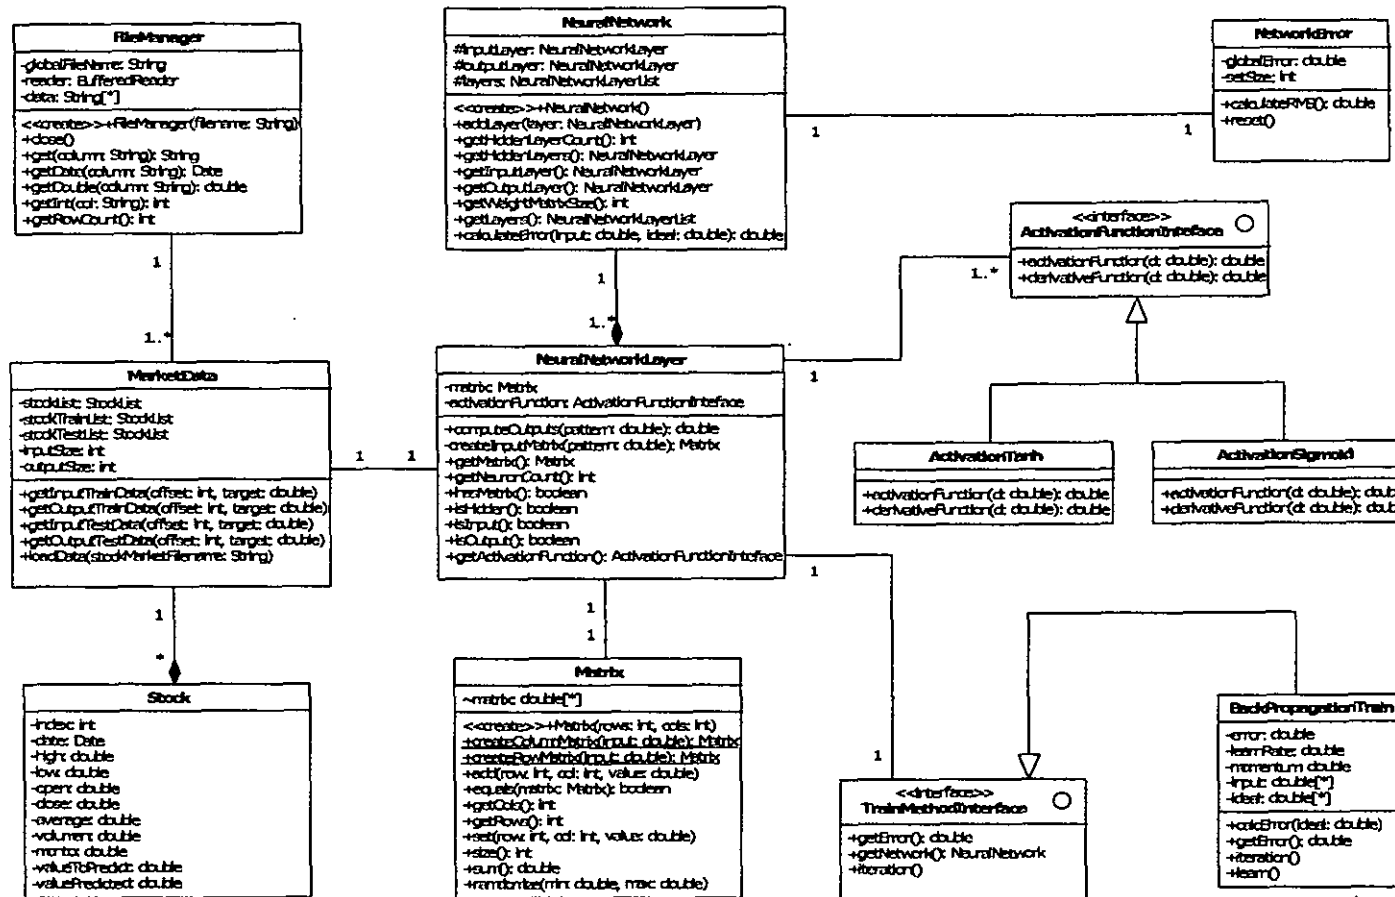


Figura 4.1 Diagrama de Clases de Diseño del Sistema

Fuente: Elaboración propia



## **4.4. Implementación del Sistema**

El desarrollo del Sistema ha sido realizado en lenguaje JAVA 1.5; se ha utilizado librerías gráficas Jfreechart 1.0.13 que son implementaciones de Java (<http://www.jfree.org/jfreechart/>), y como IDE de desarrollo se ha empleado Eclipse 3.7.1 ([www.eclipse.org](http://www.eclipse.org)).

El Sistema ha sido modularizado en tres componentes, para su facilidad de entendimiento y programación.

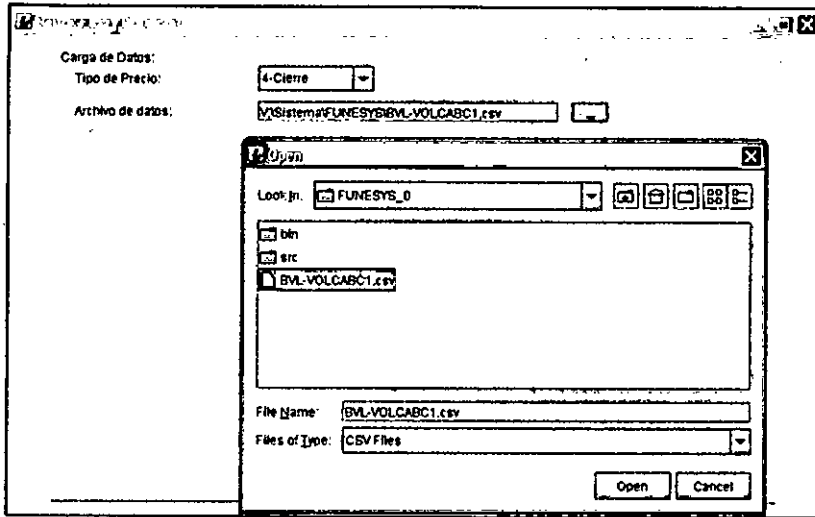
### **4.4.1. Módulos del Sistema**

#### **Componente de Carga de Datos**

Este componente se encarga de la lectura y carga de datos, en las estructuras de datos correspondientes para luego ser manejadas por el sistema.

La lectura se realiza desde un archivo \*.csv en el cual está organizado la información histórica de los datos a pronosticar, para este estudio se ha considerado principalmente el estudio del *precio de cierre de la acción por día*, sin embargo, este mismo formato soporta datos del precio de apertura, máximo y mínimo de la acción por día. Se debe tener en cuenta que antes de la carga de datos se debe escoger el tipo de precio de acción a pronosticar para que el módulo cargue únicamente la información necesaria.

Las Figuras 4.4 y 4.5 muestran el módulo de carga de datos y la estructura de los datos respectivamente.



**Figura 4.4** Módulo de Carga de Datos del Sistema

*Fuente:* Elaboración propia

	A	B	C	D	E	F
1	Fecha	Apertura	Cierre	Maximo	Minimo	Promedio
2	5/10/2011	2.38	2.45	2.45	2.38	2.44
3	4/10/2011	2.31	2.35	2.37	2.3	2.33
4	3/10/2011	2.5	2.4	2.52	2.39	2.43
5	30/09/2011	2.58	2.55	2.58	2.55	2.57
6	29/09/2011	2.62	2.61	2.65	2.6	2.62
7	28/09/2011	2.69	2.6	2.7	2.6	2.61
8	27/09/2011	2.7	2.69	2.73	2.69	2.71
9	26/09/2011	2.63	2.63	2.65	2.58	2.61
10	23/09/2011	2.7	2.63	2.71	2.63	2.66
11	22/09/2011	2.8	2.69	2.8	2.69	2.72
12	21/09/2011	2.91	2.84	2.92	2.84	2.86
13	20/09/2011	2.88	2.92	2.92	2.86	2.91
14	19/09/2011	2.86	2.88	2.89	2.86	2.88
15	16/09/2011	2.9	2.95	2.97	2.89	2.92
16	15/09/2011	2.88	2.91	2.92	2.86	2.89
17	14/09/2011	2.87	2.87	2.87	2.83	2.85
18	13/09/2011	2.85	2.85	2.85	2.82	2.83

**Figura 4.5** Estructura de los datos de Entrada del Sistema

*Fuente:* Elaboración propia.

### Componente de Procesamiento (Entrenamiento-Prueba)

Este módulo se encarga del procesamiento del modelo de red neuronal propuesto, para ello el sistema define los conjuntos de entrenamiento y prueba a partir de la información cargada previamente en el módulo de carga de datos.

En este módulo se definen además, los parámetros para el entrenamiento de la red: número de neuronas de entrada, número de neuronas en la capa oculta, tipo de algoritmo de aprendizaje, número de iteraciones máximas y el error máximo permitido en el entrenamiento.

La Figura 4.6 muestra el módulo de procesamiento con la respectiva definición de los parámetros.

The screenshot shows a software window titled "NeuroFuzzy Predict". It contains several sections for configuring the neural network training process:

- Conjuntos de Entrenamiento:**
  - Data de Entrenamiento (desde): 01/01/2007
  - Data de Prueba (desde): 01/01/2010
  - Architectura de la Red: 01/01/2010, 01/01/2011
- # NEURONAS:**
  - Capa de Entrada: 5
  - Capa Oculta: 4
  - Capa de Salida: 1
- Parámetros de Entrenamiento:**
  - Algoritmo: 1-Backpropagation
  - Max. Error Permido: 0.01
  - Max. Nro Iteraciones: 3000

At the bottom of the window, there are two buttons: "Ejecutar" and "Ver Resultados".

**Figura 4.6** Módulo de Procesamiento del Sistema

**Fuente:** Elaboración propia.

## Componente de Reportes

Este módulo se encarga de realizar la presentación de los resultados. Para cada uno de los datos del conjunto de prueba se presentan los resultados del pronóstico calculado, además se muestran las medidas de rendimiento alcanzadas por el modelo (Error cuadrático medio MSE, Raíz del error cuadrático medio RMSE y Error porcentual absoluto medio MAPE).

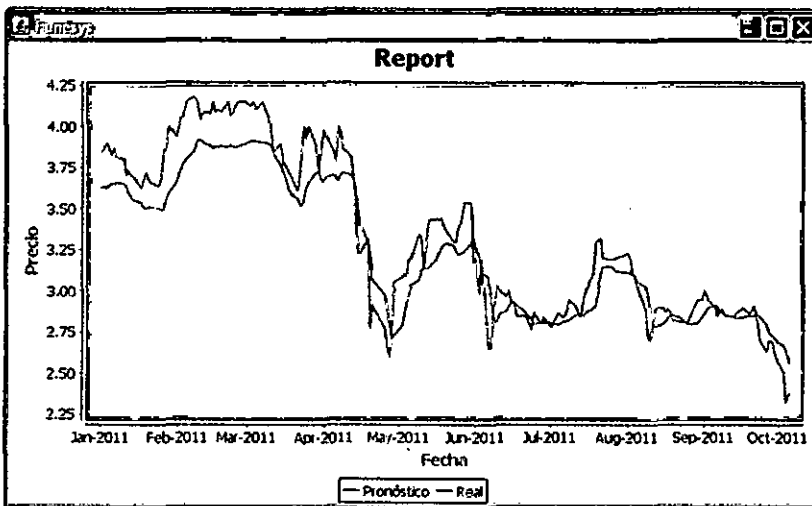
Este módulo muestra además, los resultados obtenidos del comportamiento del precio de la acción por día de manera gráfica, tal y como se muestra en la Figura 4.8.

La Figura 4.7 muestra el módulo de reportes con sus respectivos parámetros de rendimiento alcanzados.

Fecha	Real	Pronóstico	Error	Valor
01/01/2011	3.84	3.6783	MSE	0.0332
03/01/2011	3.9	3.6319	RMSE	0.1822
05/01/2011	3.83	3.6529	MAPE (%)	4.2855
06/01/2011	3.87	3.6516	MPE (%)	2.207
07/01/2011	3.81	3.6614		
10/01/2011	3.8	3.6488		
11/01/2011	3.7	3.6381		
12/01/2011	3.73	3.5957		
12/01/2011	3.7	3.472		

**Figura 4.7** Módulo de Reportes del Sistema

Fuente: Elaboración propia



**Figura 4.8** Reporte gráfico del comportamiento del pronóstico

Fuente: Elaboración propia

## **CAPÍTULO V**

### **EXPERIMENTOS NUMÉRICOS**

#### **5.1. Hardware y Software utilizado**

##### **5.1.1. Hardware**

El hardware utilizado en la realización de la ejecución de los modelos tuvo las siguientes características:

- Procesador Intel(R) Core (TM) i5.
- Velocidad de 2.27GHz.
- Memoria RAM 1024MB.

##### **5.1.2. Software**

El software utilizado consistió de:

- Sistema Operativo Ubuntu 10.04 Lucid.
- Java JDK y JRE 1.6.0\_20
- IDE Eclipse Helios 3.6

## 5.2. Datos utilizados para las pruebas

Existen varios tipos de datos que pueden ser empleados en la predicción de series de tiempo, los cuales generalmente son agrupados en dos categorías:

datos técnicos y datos fundamentales [Hellström+ 1998]. Los datos técnicos incluyen datos como precios de acciones, volumen, volatilidad, etc. Para nuestro modelo se ha utilizado, el precio de cierre de la acción por día:

$Y_t$  : Precio de cierre de la acción por día

Para este estudio de investigación se ha elegido una de las empresas más grandes del sector minero en el Perú: Volcan. Se ha considerado la información histórica del precio de sus acciones comercializadas en la Bolsa de Valores de Lima en el periodo comprendido entre enero del 2007 y Junio del 2012.

**Tabla 5.1** Información Básica del Emisor de Volcan

*Fuente:* Bolsa de Valores de Lima

DATOS BÁSICOS DEL EMISOR	
Emisor	VOLCAN COMPAÑIA MINERA S.A.A
RUC	20383045267
Dirección	Av. Gregorio Escobedo N° 710 - Jesús María
Ciudad	Lima
Representante legal	Juan José HERRERA TAVARA
Web Site:	<a href="http://www.volcan.com.pe">www.volcan.com.pe</a>
Fundación	01/02/1998

**Tabla 5.2** Información Básica de Volcan

*Fuente:* Bolsa de Valores de Lima

DATOS BÁSICOS DEL TÍTULO	
Mnemotécnico	VOLCAN
Código	VOLCABC1
Nro de acciones en circulación	1,249,669,371
Nro de accionistas	8,841
Valor nominal	S/. 1.00
Fecha de Listado en la BVL	31/03/1998

En el periodo de estudio (desde enero-2007 hasta junio-2012), se han identificado 1368 datos históricos para cada una de las variables utilizadas en el estudio, los cuales se dividieron en dos conjuntos de datos:

*Patrones de entrenamiento:* Desde el 1 de enero del 2007 hasta el 31 de diciembre del 2011 (1250 datos), lo que representa aproximadamente el 91% de los datos de la serie de tiempo, y serán utilizados para el entrenamiento del modelo propuesto.

*Patrones de prueba:* Desde el 1 de enero del 2012 hasta el 18 de Junio del 2012 (118 datos), lo que representa aproximadamente el 9% de los datos de la serie de tiempo, y serán utilizados para la evaluación de la capacidad de predicción del modelo propuesto.

El Anexo 2 muestra los datos históricos en el periodo de estudio utilizados en esta investigación.

### **5.3. Modelo Box-Jenkins (ARIMA) para las pruebas**

Teóricamente El precio, el valor de una acción depende temas propios que le pasen a la empresa o Riesgos independientes o variables relacionadas a la empresa (gerencia, costos, eficiencia) y a Riesgos sistémicos (que le pasa a la economía, al precio de los minerales, a la economía internacional, etc.) en general lo que le pueda pasar al día a día es muy complicado estimarlo, lo que si tiene influencia es la Tendencia.

Para proceder con las pruebas se aplicó una estrategia iterativa para la construcción del modelo que consiste en tres fases:

**Fase 1.** Selección de un modelo inicial (**Identificación del modelo**),

**Fase 2.** Estimación de coeficientes del modelo (**estimación de parámetros**)

**Fase 3.** Análisis de residuos (**verificación del modelo**). Si es necesario, el modelo inicial se modifica y el proceso se repite hasta que los residuos indiquen que ya no es necesaria otra modificación.

-Si el análisis de residuos es favorable, estaremos en condiciones de utilizar el modelo ajustado para pronosticar (Pronósticos con el modelo verificado).

**En la práctica:**

1- Identificar de acuerdo al FAS, FAP y la gráfica, los posibles modelos

2- Estimar parámetros

3- Análisis de parámetros y residuos para elegir el mejor modelo:

\*Significativos todos los t de Student, mayor que 2 en valor absoluto.

\*El Durwin Watson deben ser alrededor de 2.

\*El error debe ser un ruido blanco.


\*Usamos Akaike o (Shwartz o Bayesiano) para ver la calidad del modelo, el que tiene el menor valor es el mejor modelo.

### **5.3.1. Fase 1. Identificación del modelo**

Analizando la gráfica de datos presentada, en la figura 5.1, podemos notar una tendencia descendente hasta finales del 2008, luego se observa una




ligera recuperación de la acción en estudio hasta mediados del 2009, posterior a este año se observa cierta estabilidad en el precio (con pequeños altibajos), que se mantiene hasta la actualidad.



**Figura 5.1** Ploteo de la data de entrenamiento.  
Fuente: Elaboración propia.

- **Análisis de la Tendencia**

En general la tendencia para la data de entrenamiento es descendente, tal como se muestra en la figura 5.2.



**Figura 5.2** Tendencia de la data de entrenamiento.  
*Fuente: Elaboración propia.*

Además, en la figura 5.3 se ve las auto correlaciones muestrales, las primeras auto correlaciones son persistentemente grandes, y tienden a 0 con lentitud, por lo que esta serie es No Estacionaria y su media y varianza no varían alrededor de un nivel fijo. Además, su distribución de probabilidad no cambia cuando se desplaza en el tiempo.

Dado que la serie no es estacionaria se procedió a inducir la estacionariedad de la misma.

Sample: 1 1250  
 Included observations: 1250

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.998	0.998	1248.8	0.000
		2	0.996	-0.165	2493.1	0.000
		3	0.994	-0.033	3732.4	0.000
		4	0.991	-0.014	4966.5	0.000
		5	0.989	0.028	6195.6	0.000
		6	0.986	0.009	7419.7	0.000
		7	0.984	-0.064	8638.5	0.000
		8	0.981	-0.043	9851.5	0.000
		9	0.978	-0.020	11058.	0.000
		10	0.975	-0.029	12259.	0.000
		11	0.972	0.029	13453.	0.000
		12	0.969	-0.028	14640.	0.000
		13	0.966	-0.062	15821.	0.000
		14	0.963	-0.024	16995.	0.000
		15	0.959	0.012	18161.	0.000
		16	0.956	0.044	19320.	0.000
		17	0.953	-0.016	20472.	0.000
		18	0.949	0.014	21617.	0.000
		19	0.946	-0.046	22755.	0.000
		20	0.943	-0.044	23885.	0.000
		21	0.939	-0.049	25007.	0.000
		22	0.935	-0.020	26121.	0.000
		23	0.931	0.053	27226.	0.000
		24	0.927	0.018	28324.	0.000
		25	0.924	-0.003	29414.	0.000
		26	0.920	0.015	30496.	0.000
		27	0.916	-0.014	31570.	0.000
		28	0.912	-0.046	32636.	0.000
		29	0.909	0.006	33694.	0.000
		30	0.905	-0.003	34744.	0.000
		31	0.901	0.046	35786.	0.000
		32	0.897	0.026	36820.	0.000
		33	0.894	0.015	37847.	0.000
		34	0.890	0.034	38867.	0.000
		35	0.887	0.007	39880.	0.000
		36	0.884	0.015	40887.	0.000

**Figura 5.3** Auto correlación y autocorrelación parcial de la data de entrenamiento.

*Fuente: Elaboración propia.*

La serie original no es estacionaria porque la función de auto correlación simple no cae rápido a cero.

Dado que el modelo Arima se debe aplicar a series estacionarias, convertiremos nuestra serie original en estacionaria.

Se procedió a diferenciar la serie (primeras diferencias) para ver si se convierte en una serie estacionaria.

## La estacionariedad

En cuanto a la estacionariedad, hay 3 conceptos por las cuales se sabe si es o no es estacionaria la serie analizada:


\*Fuerte cuando supone que la función de distribución que está en la serie (normal, poisson o cualquier función de distribución) es constante en el tiempo invariante en el tiempo.

\*Estricto cuando ya se va a los momentos la esperanza, varianza covarianza son constantes la Kurtosis 3 y la Skewness (sesgo) = 0 para que tenga buena simetría y buena dispersión.

\*Débil (se usa en la práctica) solo las 3 primeras de la estricta, cuando esperanza varianza y covarianza sean constantes en el tiempo, es lo que se usa en la práctica y lo que usaremos en el presente trabajo.

El R2 es bueno cuando las variables son estacionarias, pero cuando se habla de series de tiempo, no se habla de r2, sino se habla en mínimos cuadrados ordinarios y en modelos simples.

La figura 5.4 muestra los datos diferenciados con retraso 1, y se observa que varía alrededor de un nivel fijo.



**Figura 5.4** Ploteo de la data de entrenamiento con dif. de orden 1.

*Fuente: Elaboración propia.*

Una vez obtenida la serie estacionaria, procedimos a comparar las correlaciones y correlaciones parciales de la serie diferenciada (Figura 5.5) con las correlaciones y correlaciones parciales teóricas.

Sample: 1 1250  
Included observations: 1249

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.253	0.253	79.910	0.000
		2	0.090	0.028	89.972	0.000
		3	0.054	0.027	93.659	0.000
		4	-0.009	-0.033	93.753	0.000
		5	-0.009	-0.003	93.855	0.000
		6	0.074	0.083	100.67	0.000
		7	0.080	0.049	108.75	0.000
		8	0.055	0.018	112.59	0.000
		9	0.063	0.035	117.67	0.000
		10	-0.014	-0.046	117.93	0.000
		11	0.029	0.045	118.99	0.000
		12	0.087	0.075	128.60	0.000
		13	0.060	0.018	133.14	0.000
		14	-0.007	-0.048	133.21	0.000
		15	-0.042	-0.054	135.40	0.000
		16	-0.025	0.001	136.18	0.000
		17	-0.027	-0.009	137.09	0.000
		18	0.065	0.073	142.45	0.000
		19	0.102	0.062	155.55	0.000
		20	0.115	0.063	172.33	0.000
		21	0.069	0.014	178.37	0.000
		22	-0.077	-0.110	185.82	0.000
		23	-0.044	0.003	188.27	0.000
		24	-0.037	-0.023	189.99	0.000
		25	-0.030	-0.024	191.14	0.000
		26	0.026	0.028	191.99	0.000
		27	0.088	0.065	201.83	0.000
		28	-0.000	-0.035	201.83	0.000
		29	0.001	0.004	201.84	0.000
		30	-0.074	-0.091	208.78	0.000
		31	-0.058	-0.022	213.16	0.000
		32	-0.034	-0.031	214.64	0.000
		33	-0.049	-0.038	217.76	0.000
		34	-0.040	0.002	219.85	0.000
		35	-0.027	0.006	220.81	0.000
		36	-0.004	0.019	220.84	0.000

**Figura 5.5** Auto correlación y Autocorrelacion parcial de la data de entrenamiento con dif. de orden 1.

Fuente: Elaboración propia.

Interpretación de las gráficas de autocorrelaciones y correlaciones parciales:

**AR(1)**

FAS FAP (su grafica fluctúa alrededor de una constante)

FAS cae rápido converge rápido a cero exponencialmente y la FAP solo es significativa en el primer rezago.

### **AR(2)**

Gráfica igual que AR(1) solo cambia el parcial 2 rezagos significativos.

### **MA(1)**

Es al revés que AR(1)

FAS solo es significativa en el primer rezago y FAP cae rápido converge a cero.

### **ARMA(1,1)**

Las gráficas fluctúan alrededor de un promedio, (sobreponer las gráficas anteriores no sumar las gráficas).

Los dos son significativos hasta el primero y de allí cae rápido a cero.

Se obtiene, que los modelos sugeridos para la serie estacionaria son:

AR(1), MA(1), ARMA(1,1), MA(2), ARIMA(2,1,1).

## **5.3.2. Fase 2. Estimación de parámetros**

Para la estimación de parámetros, se usó el programa Eviews y Minitab, los resultados se pueden ver en las siguientes tablas por cada modelo sugerido:

### **AR(1):**

Dependent Variable: DVOLCAN  
Method: Least Squares  
Sample (adjusted): 3 1250  
Included observations: 1248 after adjustments  
Convergence achieved after 3 iterations

---

Variable	Coefficient	Std. Error	t-Statistic	Prob.
----------	-------------	------------	-------------	-------

---

C	-0.003982	0.007000	-0.568847	0.5696
AR(1)	0.252638	0.027408	9.217722	0.0000
R-squared	0.063838	Mean dependent var	-0.004014	
Adjusted R-squared	0.063087	S.D. dependent var	0.190935	
S.E. of regression	0.184814	Akaike info criterion	-0.537332	
Sum squared resid	42.55866	Schwarz criterion	-0.529112	
Log likelihood	337.2952	F-statistic	84.96639	
Durbin-Watson stat	2.013986	Prob(F-statistic)	0.000000	
Inverted AR Roots	.25			

Para que C sea diferente de cero, el valor t-Statistic de la variable C en valor absoluto debe ser mayor de 2 ó su probabilidad debe ser menor que 0.05, entonces como C es 0, la nueva ecuación sería:

Dependent Variable: DVOLCAN  
Method: Least Squares  
Sample (adjusted): 3 1250  
Included observations: 1248 after adjustments  
Convergence achieved after 2 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.252974	0.027394	9.234612	0.0000
R-squared	0.063595	Mean dependent var	-0.004014	
Adjusted R-squared	0.063595	S.D. dependent var	0.190935	
S.E. of regression	0.184764	Akaike info criterion	-0.538675	
Sum squared resid	42.56970	Schwarz criterion	-0.534565	
Log likelihood	337.1333	Durbin-Watson stat	2.014153	
Inverted AR Roots	.25			

### MA(1):

Dependent Variable: DVOLCAN  
Method: Least Squares  
Sample (adjusted): 2 1250  
Included observations: 1249 after adjustments  
Convergence achieved after 6 iterations  
Backcast: 0

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.004099	0.006467	-0.633877	0.5263
MA(1)	0.233441	0.027535	8.477833	0.0000
R-squared	0.058288	Mean dependent var	-0.004091	

Adjusted R-squared	0.057532	S.D. dependent var	0.190878
S.E. of regression	0.185306	Akaike info criterion	-0.532022
Sum squared resid	42.81966	Schwarz criterion	-0.523807
Log likelihood	334.2475	F-statistic	77.18343
Durbin-Watson stat	1.968181	Prob(F-statistic)	0.000000

---

Inverted MA Roots      -.23

---

Para que C sea diferente de cero, el valor t-Statistic de la variable C en valor absoluto debe ser mayor de 2 ó su probabilidad debe ser menor que 0.05, entonces como C es 0, la nueva ecuación sería:

Dependent Variable: DVOLCAN  
Method: Least Squares  
Sample (adjusted): 2 1250  
Included observations: 1249 after adjustments  
Convergence achieved after 6 iterations  
Backcast: 0

---

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.233662	0.027523	8.489773	0.0000

---

R-squared	0.057984	Mean dependent var	-0.004091
Adjusted R-squared	0.057984	S.D. dependent var	0.190878
S.E. of regression	0.185261	Akaike info criterion	-0.533301
Sum squared resid	42.83345	Schwarz criterion	-0.529193
Log likelihood	334.0463	Durbin-Watson stat	1.968024

---

Inverted MA Roots      -.23

---

### ARMA(1,1):

Dependent Variable: DVOLCAN  
Method: Least Squares  
Sample (adjusted): 3 1250  
Included observations: 1248 after adjustments  
Convergence achieved after 8 iterations  
Backcast: 0

---

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.003954	0.007268	-0.544111	0.5865
AR(1)	0.373138	0.102360	3.645349	0.0003
MA(1)	-0.129204	0.109418	-1.180833	0.2379

---



R-squared	0.064713	Mean dependent var	-0.004014
Adjusted R-squared	0.063211	S.D. dependent var	0.190935
S.E. of regression	0.184802	Akaike info criterion	-0.536665
Sum squared resid	42.51887	Schwarz criterion	-0.524335
Log likelihood	337.8788	F-statistic	43.07129
Durbin-Watson stat	1.998200	Prob(F-statistic)	0.000000
<hr/>			
Inverted AR Roots	.37		
Inverted MA Roots	.13		

Para que C sea diferente de cero, el valor t-Statistic de la variable C en valor absoluto debe ser mayor de 2 ó su probabilidad debe ser menor que 0.05, entonces como C es 0, la nueva ecuación sería:

Dependent Variable: DVOLCAN  
Method: Least Squares  
Sample (adjusted): 3 1250  
Included observations: 1248 after adjustments  
Convergence achieved after 8 iterations  
Backcast: 0

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.374793	0.102060	3.672293	0.0003
MA(1)	-0.130662	0.109156	-1.197028	0.2315
<hr/>				
R-squared	0.064491	Mean dependent var	-0.004014	
Adjusted R-squared	0.063740	S.D. dependent var	0.190935	
S.E. of regression	0.184750	Akaike info criterion	-0.538030	
Sum squared resid	42.52897	Schwarz criterion	-0.529810	
Log likelihood	337.7306	Durbin-Watson stat	1.998134	
<hr/>				
Inverted AR Roots	.37			
Inverted MA Roots	.13			

## MA(2):

Dependent Variable: DVOLCAN  
Method: Least Squares  
Sample (adjusted): 2 1250  
Included observations: 1249 after adjustments  
Convergence achieved after 7 iterations  
Backcast: ? 0

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.004100	0.006840	-0.599333	0.5491
MA(1)	0.241473	0.028268	8.542321	0.0000
MA(2)	0.065747	0.028268	2.325830	0.0202
R-squared	0.062500	Mean dependent var		-0.004091
Adjusted R-squared	0.060996	S.D. dependent var		0.190878
S.E. of regression	0.184965	Akaike info criterion		-0.534904
Sum squared resid	42.62810	Schwarz criterion		-0.522582
Log likelihood	337.0475	F-statistic		41.53357
Durbin-Watson stat	1.991595	Prob(F-statistic)		0.000000
Inverted MA Roots	-.12+.23i	-.12-.23i		

Para que C sea diferente de cero, el valor t-Statistic de la variable C en valor absoluto debe ser mayor de 2 ó su probabilidad debe ser menor que 0.05, entonces como C es 0, la nueva ecuación sería:

Dependent Variable: DVOLCAN  
Method: Least Squares  
Sample (adjusted): 2 1250  
Included observations: 1249 after adjustments  
Convergence achieved after 7 iterations  
Backcast: ? 0

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.241711	0.028256	8.554355	0.0000
MA(2)	0.065980	0.028257	2.335046	0.0197
R-squared	0.062230	Mean dependent var		-0.004091
Adjusted R-squared	0.061478	S.D. dependent var		0.190878
S.E. of regression	0.184917	Akaike info criterion		-0.536217
Sum squared resid	42.64039	Schwarz criterion		-0.528002
Log likelihood	336.8675	Durbin-Watson stat		1.991531
Inverted MA Roots	-.12-.23i	-.12+.23i		

### ARIMA(2,1,1):

Dependent Variable: DVOLCAN  
Method: Least Squares  
Sample (adjusted): 4 1250  
Included observations: 1247 after adjustments

Convergence achieved after 11 iterations  
Backcast: 0

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	1.131964	0.087863	12.88333	0.0000
AR(2)	-0.194050	0.041424	-4.684457	0.0000
MA(1)	-0.891068	0.081130	-10.98318	0.0000
R-squared	0.068082	Mean dependent var		-0.003978
Adjusted R-squared	0.066583	S.D. dependent var		0.191007
S.E. of regression	0.184539	Akaike info criterion		-0.539514
Sum squared resid	42.36377	Schwarz criterion		-0.527176
Log likelihood	339.3869	Durbin-Watson stat		1.998243
Inverted AR Roots	.92	.21		
Inverted MA Roots	.89			

**Para seleccionar el mejor modelo debemos considerar los siguientes criterios:**

- \* Significativos todos los t de Student, más que 2 en valor absoluto.
- \* El Durwin Watson deben ser alrededor de 2.
- \* Usaremos Akaike o (Shwartz o Bayesiano) para ver la calidad del modelo, el menor valor indica que es el mejor modelo.

Se obtiene que el modelo que mejor ajusta, es ARIMA (2,1,1), debido a la comparación con los modelos teóricos y análisis de los parámetros.

### 5.3.3. Fase 3. Verificación del modelo - Análisis de Residuos

- El error del modelo seleccionado debe ser un ruido blanco.

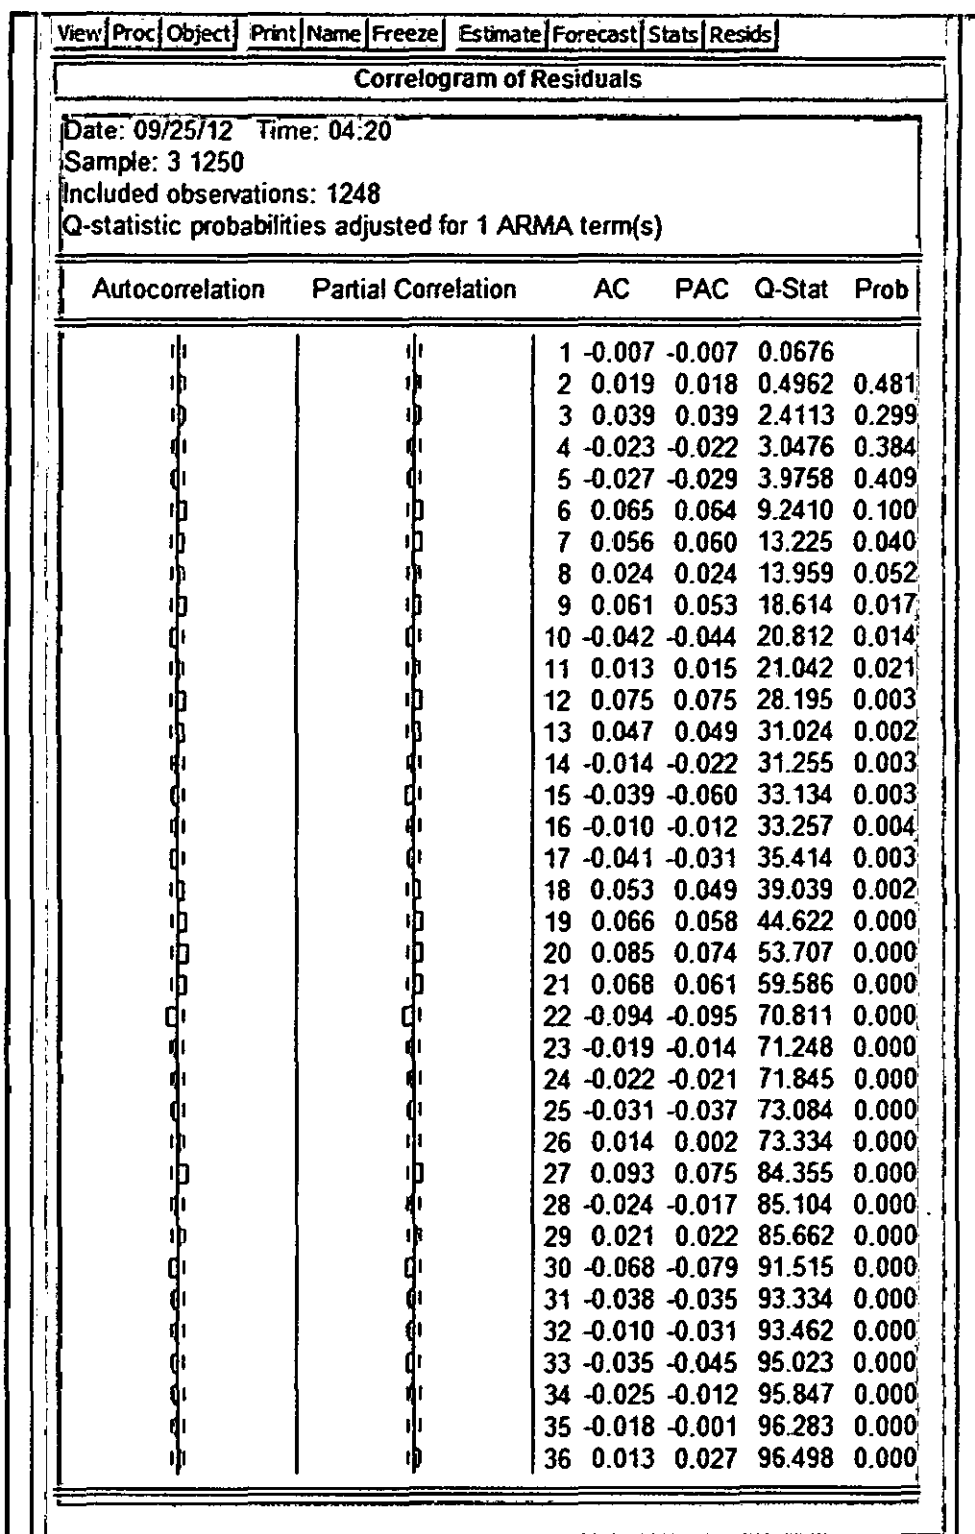
El ruido blanco, es un proceso estocástico que no tienen pasado, son innovaciones, es decir, es resultado del azar ( $Y_t = error$ ).

Una serie  $\{Y_t\}$  es denominada ruido blanco si su media es igual a cero, su varianza es constante y los elementos de la serie no se correlacionan entre sí.

De la forma en que se ha definido el proceso ruido blanco es fácil determinar que este cumple con las características de estacionariedad débil ya que mantiene constante sus dos primeros momentos a lo largo de la serie.

Los estadísticos Q de Ljung-Box calculados, no son significativos como lo indicaron los valores grandes de p. La prueba de Ljung-Box se utiliza comúnmente en un modelo auto regresivo integrado de media móvil (ARIMA).

Nótese que lo aplicamos a los residuos del modelo ajustado ARIMA, no a la serie original, la hipótesis que en realidad se está probando, es que los residuos del modelo ARIMA no tienen auto correlación, es decir que los residuos son independientemente distribuidos. En la figura 5.6 se observa que no existe auto correlación residual significativa para el modelo.



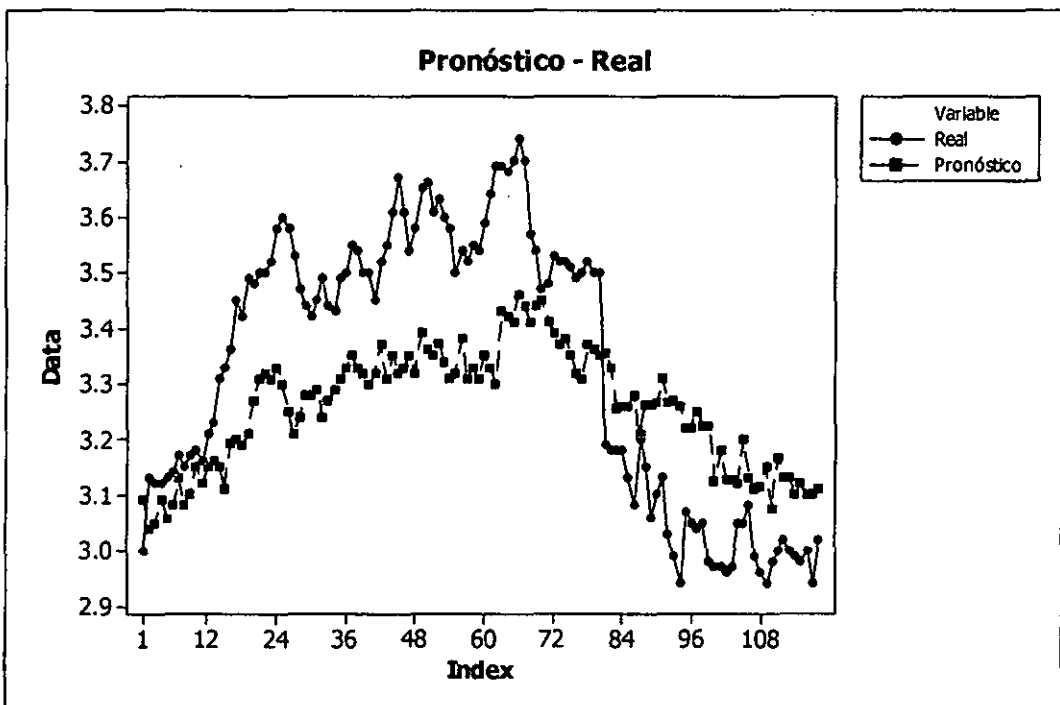
**Figura 5.6** Auto correlación y Auto correlación parcial de los residuos.  
**Fuente:** Elaboración propia.

#### 5.3.4. Pronóstico con el modelo verificado

Finalmente se presenta el ajuste a la serie de tiempo de las acciones de la minera VOLCAN y el pronóstico en gráficas consecutivas trimestrales, para facilitar su observación.

El Pronóstico se realizó para el periodo 2012, utilizando data histórica del periodo comprendido entre los años 2007 – 2011.

Los resultados obtenidos para el pronóstico se pueden ver en la figura 5.7.



*Figura 5.7 Curva pronosticada vs curva real.  
Fuente: Elaboración propia.*

El error cuadrático medio MSE al que se llegó con el modelo ARIMA fue de 0.01737.

#### 5.4. Modelos de Redes Neuronales Artificiales para las pruebas.

Para la ejecución de las pruebas de rendimiento del modelo propuesto se procedió a definir distintas topologías para el modelo, los mismos que se diferencian principalmente en la cantidad de neuronas utilizadas en las capas de entrada y las capas ocultas.

Se definió una topología de red con las siguientes características:

- Red Multicapa Unidireccional o Perceptrón Multicapa (MLP), es decir una red con conexiones que pasan las salidas en una única dirección a neuronas en la siguiente capa.

-*Número de entradas:*  $p$

-*Número de capas ocultas:* 1

-*Número de neuronas en la capa oculta:*  $q$

-*Función de activación:* Sigmoidal.

Al igual que en la determinación de las entradas, no existe una regla general para la obtención de los parámetros de la red que se desempeña mejor en cada situación. Se realiza entonces un procedimiento automático de búsqueda, por medio de un "barrido" de los parámetros que determinan el comportamiento de la red, por lo que, para obtener los parámetros de la red neuronal que arroja el menor error tanto en el ajuste como en la predicción.

El criterio de evaluación estará dado por el Error Cuadrático Medio (MSE), el mismo que se calcula mediante:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2$$

$Y_t$  = Valor del precio de cierre en el día  $t$

$\hat{Y}_t$  = Valor pronosticado de  $Y_t$

$e_t = Y_t - \hat{Y}_t$  = Residuo o error de pronóstico

La Tabla 5.5 muestra 15 modelos con distintas topologías consideradas para cada una de las pruebas realizadas en nuestro experimento.

**Tabla 5.3** Modelos y Topologías de prueba.

Fuente: Elaboración propia.

Modelo de Prueba	Topología (p-q-1)	Función de Activación	Algoritmo de Entrenamiento	Iteraciones Max.	Error Max.
Modelo 1	5-3-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 2	5-5-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 3	5-10-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 4	8-5-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 5	8-8-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 6	8-10-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 7	10-5-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 8	10-10-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 9	10-15-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 10	10-20-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 11	15-10-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 12	15-15-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 13	15-20-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 14	20-15-1	Sigmoidal	Backpropagation	5000	0.005
Modelo 15	20-20-1	Sigmoidal	Backpropagation	5000	0.005

## 5.5. Experimentos Numéricos

Luego de entrenar y evaluar cada uno de los modelos definidos en la Tabla 5.5, se obtuvieron los resultados mostrados en la tabla 5.6.

**Tabla 5.4** Resultados obtenidos para cada uno de los modelos de prueba.

Fuente: Elaboración propia.

Modelo de Prueba	Topología	MSE	RMSE	MAPE(%)	MPE(%)
Modelo 1	5-3-1	0.0122	0.1103	2.7352	1.0987
<b>Modelo 2</b>	<b>5-5-1</b>	<b>0.0108</b>	<b>0.1039</b>	<b>2.6444</b>	<b>-0.3296</b>
Modelo 3	5-10-1	0.0121	0.1099	2.7692	-1.3200




Modelo 4	8-5-1	0.0250	0.1580	3.9061	3.3928
Modelo 5	8-8-1	0.0121	0.1101	2.7494	-0.2673
<b>Modelo 6</b>	<b>8-10-1</b>	<b>0.0106</b>	<b>0.1031</b>	<b>2.6348</b>	<b>-0.8091</b>
Modelo 7	10-5-1	0.0119	0.1091	2.7259	0.1132
Modelo 8	10-10-1	0.0320	0.1790	4.5154	4.3209
<b>Modelo 9</b>	<b>10-15-1</b>	<b>0.0116</b>	<b>0.1075</b>	<b>2.6866</b>	<b>0.3262</b>
Modelo 10	10-20-1	0.0287	0.1695	4.1721	3.7955
Modelo 11	15-10-1	0.0126	0.1124	2.8019	0.5992
Modelo 12	15-15-1	0.0136	0.1166	2.8395	-0.6364
Modelo 13	15-20-1	0.0171	0.1307	3.3041	1.5278
Modelo 14	20-15-1	0.0174	0.1318	3.3927	1.2041
Modelo 15	20-20-1	0.0147	0.1213	3.0271	-0.6347

Durante la ejecución de los experimentos se observó que la convergencia en los modelos con un número de neuronas de entrada mayores a 15 es mínima, además, el tiempo de procesamiento en estos modelos fue alto. Por el contrario, los modelos con un número de neuronas en la capa de entrada menores o iguales a 10, presentaron mejores niveles de convergencias y menores tiempos de procesamiento.

Las figuras 5.10 y 5.11 muestran las gráficas de los modelos 2 y 6, los cuales presentan menores valores del Error Cuadrático Medio respectivamente, así como los valores reales y pronosticados obtenidos con la aplicación de los respectivos modelos, que según nuestros experimentos, obtienen los mejores resultados en el pronóstico de precios de acciones.


**Acción: VOLCABC1**



**Figura 5.8** Gráfico del pronóstico utilizando el Modelo 2.

**Fuente:** Elaboración propia.

**Acción: VOLCABC1**



**Figura 5.9** Gráfico del pronóstico utilizando el Modelo 6.

**Fuente:** Elaboración propia.

## **Comparación de MSEs entre el mejor modelo de Redes Neuronales vs el mejor modelo ARIMA**

De acuerdo a los experimentos realizados, los mejores resultados que se han conseguido, esto es, los que tienen los menores Errores Cuadrático Medio MSE son:

MSE RNA(8-10-1): 0.0106

MSE ARIMA(2,1,1): 0.01737

Por lo tanto se concluye que el modelo de redes neuronales se ajusta mejor a la data real, en aproximadamente 64.15% respecto al modelo ARIMA.

## **CONCLUSIONES Y RECOMENDACIONES**

### **Conclusiones**

Este trabajo de investigación presenta los fundamentos para la construcción de un modelo de Redes Neuronales Artificiales para el pronóstico de precios de acciones comercializadas en el mercado de valores del Perú; la propuesta nos presenta un modelo novedoso para el pronóstico de los precios de acciones. De este modo, se intenta obtener un modelo de mejor desempeño que refleje el comportamiento y las fluctuaciones de los precios de las acciones comercializadas en el mercado de valores del Perú.

Los resultados muestran que los modelos basados en Redes Neuronales Artificiales pueden aplicarse al pronóstico de las series de tiempo financieras en los mercados de valores y lograr buenas aproximaciones ( $MSE < 0.02$ ) debido a sus capacidades para el reconocimiento de patrones. Es importante realizar un trabajo exhaustivo en la identificación y obtención de los datos históricos y periodos de la serie de tiempo, además, se debe definir una arquitectura consistente para el modelo de redes neuronales que permita obtener buenos resultados de aproximación en el pronóstico de los precios de las acciones comercializadas en la Bolsa de Valores de Lima.

De la ejecución de los experimentos, se observó que los mejores resultados fueron obtenidos con modelos en los cuales el número de neuronas de entrada fueron menores o iguales a 10 y el número de neuronas ocultas

fueron mayores o iguales al número de neuronas en la capa de entrada, como se observa en los modelos 6, 2 y 9.

Los mejores resultados se obtuvieron con el modelo 6, seguido por los modelos 2 y 9 respectivamente, que son los modelos que poseen los menores errores cuadráticos medios MSEs. En general, los modelos no muestran una diferencia significativa en el valor de los errores cuadráticos medios; salvo los modelos 6 (MSE=0.0106) y 2 (MSE=0.0108), todos los demás poseen un nivel de error muy similar, lo cual nos lleva a plantear que en general los modelos basados en Redes Neuronales Artificiales consiguen un buen nivel de aproximación en el cálculo de los pronósticos en los mercados de valores. Además, el modelo 6, con error cuadrático medio más bajo (MSE = 0.0106), presenta un pequeño error porcentual medio (MPE=-0.8091%), que indica que la técnica no presenta mucho sesgo, puesto que el valor es muy cercano a cero.

Los resultados obtenidos en este estudio en el que se han considerado 15 modelos de RNA contra el pronóstico realizado por la metodología ARIMA, demuestran que el modelo de RNA obtiene mejores resultados en el pronóstico de series de tiempo financieras frente a métodos estadísticos tradicionales de pronóstico y pueden ser utilizados como una primera fuente de información que permita a expertos, analistas bursátiles y especialistas en mercados de valores esbozar el comportamiento futuro de los precios de acciones del mercado de valores del Perú para tomar mejores decisiones de inversión bursátil, y por tanto, disminuir el riesgo de tomar una decisión errada.

El modelo de pronóstico utilizado en esta investigación ha sido aplicado a una acción específica en la Bolsa de Valores de Lima, por tanto, su aplicación y uso se limita a ésta; cada vez que se requiera utilizar el modelo para otra acción determinada en el mercado de valores del Perú, se deberá volver a ejecutar y entrenar la red para su adecuado uso.

Si bien los resultados obtenidos nos sugieren un alto grado de aproximación en el pronóstico realizado, la característica más importante a tomar en cuenta en esta investigación es la aproximación a la 'tendencia' del comportamiento del precio de la acción en el tiempo al que se ha llegado, lo cual permite tomar mejores decisiones de inversión; sin embargo se debe tener cuidado de tomar decisiones en el largo plazo debido a las condiciones de aleatoriedad propias de los mercados de valores que son muy sensibles a factores externos: económicos, políticos, sociales, etc.

### **Recomendaciones**

En este trabajo de investigación se tomó en cuenta el enfoque del análisis técnico, esto es, se consideró información histórica del comportamiento del mercado de valores para 'descubrir' su comportamiento futuro, sin embargo no se consideró la influencia de factores externos de tipo económico, político, social, etc. que definitivamente condicionarán el comportamiento futuro del precio de las acciones en un mercado de valores, por tanto, convendría desarrollar una técnica que permita incluir además del análisis técnico, el análisis fundamental, que nos permita cuantificar en un mismo modelo la influencia de factores internos y externos en el comportamiento de los precios de acciones en la Bolsa de Valores de Lima.

Se debe tener en cuenta que existen actualmente diferentes técnicas de Inteligencia Artificial que permiten el tratamiento de variables de tipo cualitativa, por tanto, resultaría muy interesante diseñar un modelo más completo que considere la aplicación de otras técnicas como: lógica difusa, algoritmos genéticos, etc. y verificar la validez de este nuevo modelo frente al propuesto en este trabajo de investigación.

Si bien es cierto el modelo presentado en este trabajo de investigación realiza un pronóstico bastante aproximado del precio de las acciones en el tiempo, conviene evaluar su aplicabilidad en diversos sectores de la

actividad económica peruana. En este trabajo se ha tomado como objeto de estudio una empresa del sector Minería e Hidrocarburos, sin embargo, convendría evaluar el uso de éste para otro sector de la actividad económica peruana y validar allí si aplicabilidad.

Un punto importante a tomar en cuenta cuando se definen modelos de pronóstico basados en técnicas de Inteligencia Artificial, es la cantidad de datos de la muestra utilizada para el entrenamiento del modelo y para la evaluación de los resultados; se debe definir los conjuntos adecuados que permitan obtener una mejor aproximación del pronóstico.

## GLOSARIO DE TÉRMINOS.

**Autocorrelación:** En estadística, la autocorrelación de una serie temporal discreta de un proceso  $X_t$  no es más que simplemente la correlación de dicho proceso con una versión desplazada en el tiempo de la propia serie temporal.

**Autocorrelación parcial:** En el análisis de series de tiempo, la función de autocorrelación parcial (FAP) juega un papel importante en los análisis de datos destinadas a la identificación de la medida del desfase en un modelo autorregresivo.

**Caso de uso:** Un caso de uso es una descripción de los pasos o las actividades que deberán realizarse para llevar a cabo algún proceso.

**Correlación:** la correlación indica la fuerza y la dirección de una relación lineal y proporcionalidad entre dos variables estadísticas.

**Cotización:** Precio al cual se compra y vende públicamente en el mercado las mercancías, los valores y efectos públicos o mercantiles.

**Heteroscedasticidad:** En estadística se dice que un modelo de regresión lineal presenta heteroscedasticidad o heterocedasticidad cuando la varianza de las perturbaciones no es constante a lo largo de las observaciones.

**Mercado Bursátil:** Organización formal del mercado de valores propia de las Bolsas de Valores.

**Mercado de Valores:** Segmento del mercado de capitales, al que concurren ofertantes y demandantes de valores mobiliarios, en donde se transan valores negociables desde su emisión, primera colocación, transferencia, hasta la extinción del título, en que intervienen unidades deficitarias o superavitarias actuando como intermediarios los bancos, instituciones financieras y la bolsa de valores a través de sus agentes de intermediación. Está conformado por el mercado primario y el mercado secundario.



**Metodología:** conjunto de procedimientos racionales utilizados para alcanzar una gama de objetivos que rigen tareas que requieran habilidades, conocimientos o cuidados específicos.

**Modelo:** a una representación abstracta, conceptual, gráfica o visual, física, matemática, de fenómenos, sistemas o procesos a fin de analizar, describir, explicar, simular - en general, explorar, controlar y predecir- esos fenómenos o procesos. Un modelo permite determinar un resultado final a partir de unos datos de entrada.

**Parámetro:** Un parámetro es una constante o una variable que aparece en una expresión matemática y cuyos distintos valores dan lugar a distintos casos en un problema.

**Perceptrón:** es un tipo de red neuronal artificial desarrollado por Frank Rosenblatt, también puede entenderse como perceptrón la neurona artificial y unidad básica de inferencia en forma de discriminador lineal, que constituye este modelo de red neuronal artificial, esto debido a que el perceptrón puede usarse como neurona dentro de un perceptrón más grande u otro tipo de red neuronal artificial.

**Perceptrón multicapa:** es una red neuronal artificial (RNA) formada por múltiples capas, esto le permite resolver problemas que no son linealmente separables, lo cual es la principal limitación del perceptrón (también llamado perceptrón simple).

**Pronóstico:** En general, a lo que es probable que ocurra en el futuro, basándose en análisis y en consideraciones de juicio.

**Retropropagación:** La propagación hacia atrás de errores o retropropagación (del inglés backpropagation) es un algoritmo de aprendizaje supervisado que se usa para entrenar redes neuronales artificiales. El algoritmo consiste en minimizar un error (comúnmente cuadrático) por medio de descenso de gradiente, por lo que la parte esencial del algoritmo es cálculo de las derivadas parciales de dicho error con respecto a los parámetros de la red neuronal.

**Topología:** Rama de las matemáticas que estudia las propiedades de las figuras con independencia de su tamaño o forma.

## BIBLIOGRAFÍA

1. [Alvarez+ 2003]  
Álvarez, M. y Álvarez, A. (2003). Predicción no lineal de tipos de cambio: algoritmos genéticos, redes neuronales y fusión de datos. *Documentos de trabajo (Vol. 1)*, Vigo: Departamento de Economía Aplicada, Universidad de Vigo.
2. [Azoff 1994]  
Azoff, E. (1994), *Neural Network Time Series Forecasting of Financial Markets*. England: John Wiley & Sons.
3. [Burton 2003]  
Burton, G. M. (2003). *A Random Walk Down Wall Street*. (8ª ed.), New York, EE.UU.: W.W. Norton & Company.
4. [Chen+ 2003]  
Chen, A. S., Leung, M. T. y Daouk, H. (2003). Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index. *Computers & Operations Research*, 30(6), 901-92.
5. [Dorffner 1996]  
Dorffner, G. (1996). Neural Networks for Time Series Processing. *Neural Network World*, 96(4), 447-468.
6. [Eeles+, 2002]  
Eeles, P., Houston, K. y Kozaczynski, W. (2002). *Building J2EE™ Applications with the Rational Unified Process*. Boston, USA: Addison-Wesley Professional.
7. [Fernández+ 2000]  
Fernández, F., González, C. y Sosvilla, S. (2000). On the profitability of technical trading rules based on artificial neural networks: Evidence from the Madrid stock market. *Economic Letters*, 69, 89-94.
8. [Gil-Lafuente 2005]  
Gil-Lafuente, A. M. (2005). *Fuzzy Logic in Financial Analysis*. Berlín, Alemania: Springer.

9. [Hanke+ 2009]  
Hanke, E. J. y Wichern, D. W. (2010). *Business Forecasting*. (9ª ed.), Mexico: Prentice Hall.
10. [Hebb+ 1949]  
Hebb D. O. (1949). *The Organization of Behaviour: A Neuropsychological Theory*.  
New York, EE.UU.: Wiley & Sons Inc.
11. [Hellström+ 1998]  
Hellström, T. y Holmström, K. (1998). Predicting the Stock Market. Technical Report IMA-TOM-1197-07, Center of Mathematical Modeling, Suiza: Mälardalen University.
12. [Hernandez+ 2010]  
Hernandez, R., Fernandez, C. y Baptista, P. (2010). *Metodología de la Investigación*. (5ª ed.), México D.F., México: McGrawHill/Interamericana editores.
13. [Hilera+ 1995]  
Hilera, J. R., Martínez, V. J. (1995). *Redes Neuronales Artificiales, fundamentos, modelos y aplicaciones* (RA-MA, trad.). New York, EE.UU: Adison Wesley.
14. [Jung-Hua+ 1996]  
Jung-Hua, W., y Jia-Yann, L. (1996). Stock Market Trend Prediction Using ARIMA-based Neural Networks. *IEEE International Conference on*, 4, 2160 – 2165.
15. [Kaastra+ 1996]  
Kaastra, I. y Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series. *Neurocomputing Elsevier Science*, 10, 215-236.
16. [Kruchten 2000]  
Kruchten, P. (2000). *The Rational Unified Process: An Introduction*. (2ª ed.). USA: Addison-Wesley Professional.
17. [Lijuan 2002]  
Lijuan, C. (2002). Support vector machines experts for time series forecasting. *Neurocomputing*, 51, 321-339.
18. [Lizarraga 1996]  
Lizarraga, F. (1996). *Modelos Multivariantes de Previsión del Fracaso Empresarial: Una Aplicación a la Realidad de la Información Contable Española*.  
Tesis Doctoral, Universidad Pública de Navarra, Navarra, España.

19. [López+ 1996]  
López, R., y Sousa, L. (1996). Banca de Inversión en el Perú. *Publicaciones Universidad de Piura*, 288 páginas, Piura, Perú.
20. [Marín+ 2002]  
Marín, J. F. y Muñoz, K. (2002). *Comparación entre modelos de Box & Jenkins y El Modelo ANFIS en el Pronóstico de Precios de Acciones en el Corto Plazo*. Tesis de Pregrado, Universidad Nacional de Medellín - Facultad de Minas, Medellín, Colombia.
21. [Mendoza 2010]  
Mendoza, G. (2010). Conceptos generales. Accedido el 10 de Diciembre, 2010, desde <http://www.gestiopolis.com/recursos/documentos/fulldocs/ger/pronosticar.htm>
22. [McCulloch+ 1943]  
McCulloch, W. y Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115-133.
23. [Ojeda 2009]  
Ojeda, J. M. (2009). *Aplicación de redes neuronales artificiales a la predicción y control de demanda de energía eléctrica en empresas industriales*. Tesis de Maestría, Universidad Nacional de Ingeniería - Facultad de Ingeniería Industrial y de Sistemas, Lima, Perú.
24. [Panchal+ 2011]  
Panchal, G., Ganatra, A. y Kosta, Y. P. (2011). Behaviour Analysis of Multilayer Perceptrons with Multiple Hidden Neurons and Hidden Layers. *International Journal of Computer Theory and Engineering*. 3(2), 332-337.
25. [Parisi+ 2003]  
Parisi, A., Parisi, F. y Guerrero, J. L. (2003). Redes neuronales en la predicción de índices accionarios internacionales. *El Trimestre Económico*, 70, 721-74.
26. [Quispe+ 2002]  
Quispe, A. y Robles, R. I. (2002). *Sistema experto de determinación de autoavalúo*. Tesis de Pregrado, Universidad Nacional Mayor de San Marcos - Escuela Académico Profesional de Ingeniería de Sistemas, Lima, Perú.
27. [Rodríguez 1998]  
Rodríguez V. (1998). *Diccionario Bursátil, Económico y Financiero*. Lima, Perú: IGMontero.

28. [Rueda 2005]  
Rueda, A. (2005). *Para Entender la Bolsa: Financiamiento e Inversión en el mercado de valores*. (2ª ed.). México D.F., México: Cengage Learning.
29. [Sachs+ 1994]  
Sachs, J. y Larrain, F. (1994). *Macroeconomía en la Economía Global*. Mexico D.F., México: Prentice Hall Hispanoamericana S.A.
30. [Sallehuddin+ 2009]  
Sallehuddin, R. H., Shamsuddin, S. M., Hashim, S. Z. y AJITH, A. (2009). Forecasting time series data using hybrid grey relational artificial neural network and auto regressive integrated moving average. *Applied Artificial Intelligence*, 23 (5), 443-486.
31. [Shih 2001]  
Shih, Y. (1994). *Neural User's Guide*. (ver. 1.4). EE.UU.: Cheshire Engineering Corporation.
32. [Smith+ 2002]  
Smith, K. y Gupta, J. *Neural Networks in Business: Techniques and Applications*  
Pennsylvania, EE.UU.: Idea Group Publishing.
33. [Trejos+, 2003]  
Trejos, A., Nieto, S. y Carbajal, P. (2003). Modelo de predicción del precio de la acción ordinaria Cementos Argos. *Scientia et Technica*, 23, 67-72.
34. [Trippi+ 1996]  
Trippi, R. R. y Turban E. (1996). *Neural Networks in Finance and Investing Using Artificial Intelligence to Improve Real-World Performance* (ed. rev.). Chicago, USA: IRWIN Professional Publishing.
35. [Vademecum BVL 2010]  
Bolsa de Valores de Lima. (2010). *Vademécum Bursátil 2010*. Lima, Perú: Edición de la BVL.
36. [Velásquez 2004]  
Velásquez, E. C. (2004). *Pronóstico del caudal medio mensual empleando Sistemas Neurofuzzy*. Tesis de Pregrado, Escuela Superior Politécnica del Litoral - Facultad de Ingeniería en Electricidad y Computación, Guayaquil, Ecuador.
37. [Vilcapoma 2003]  
Vilcapoma, E. S. (2003). *Identificación de patrones de evasión en el sistema de administración tributaria usando tecnología data mining*.

Tesis de Maestría, Universidad Nacional de Ingeniería - Facultad de Ingeniería Industrial y de sistemas, Lima, Perú.

38. [Website BVL 2010]  
Site oficial de la Bolsa de Valores de Lima, preguntas frecuentes. Accedido el 10 de Diciembre, 2010, desde <http://www.bvl.com.pe/eduayuda.html>
39. [Wong+ 2000]  
Wong, B. K., Jiang, L. y Lam, J. (2000). A bibliography of neural network business application research. *Computers and Operations Research*, 27(11), 1045-1076.
40. [Zapata 2004]  
Zapata, E. C. (2004). *Pronóstico del caudal medio mensual, con una ventana de 12 meses, usando sistemas difusos*. Tesis de grado, Universidad Nacional de Colombia - Facultad de Minas (Ingeniería de Sistemas), Medellín, Colombia.

## ANEXOS

### Anexo 1. Índices Financieros.

#### A.F.P.

1.- Liquidez :

$$\frac{\text{Activo Corriente}}{\text{Pasivo Corriente}}$$

2.- Rotación de Activos :

$$\frac{\text{Ventas Netas}}{\text{Activo Total}}$$

3.- Solvencia :

$$\frac{\text{Pasivo Total}}{\text{Activo Total}}$$

4.- Endeudamiento Patrimonial :

$$\frac{\text{Pasivo Total}}{\text{Patrimonio}}$$

5.- Rentabilidad de Ventas Netas (%) :

$$\frac{\text{Utilidad Neta}}{\text{Ventas Netas}} * 100$$

6.- Rentabilidad del Patrimonio (%) :

$$\frac{\text{Utilidad Neta}}{\text{Patrimonio}} * 100$$

7.- Valor en Libros (%) :

$$\frac{\text{Patrimonio}}{\text{Capital Social}} * 100$$

## **BANCOS y FINANCIERAS**

**1.- Liquidez :**

$$\frac{\text{Disponible + Fondos Interbancarios + Invers. Negociables y a Vcto.}}{\text{Obligaciones con el P\u00fablico + Fondos Interb. + Dep\u00f3sitos + Adeudos}}$$

**2.- Rotaci\u00f3n de Activo :**

$$\frac{\text{(Total) Ingresos Financieros}}{\text{Activo Total}}$$

**3.- Solvencia :**

$$\frac{\text{Pasivo Total}}{\text{Activo Total}}$$

**4.- Endeudamiento Patrimonial :**

$$\frac{\text{Pasivo Total}}{\text{Patrimonio}}$$

**5.- Rentabilidad de Capital (%) :**

$$\frac{\text{Utilidad Neta}}{\text{Capital Social}} * 100$$

**6.- Rentabilidad Patrimonial (%) :**

$$\frac{\text{Utilidad Neta}}{\text{Patrimonio}} * 100$$

**7.- Valor en Libros (%) :**

$$\frac{\text{Patrimonio}}{\text{Capital Social}} * 100$$



## COMPAÑIAS DE SEGUROS

1.- Razón Corriente :

$$\frac{\text{Activo Corriente}}{\text{Pasivo Corriente}}$$

2.- Rotación de Activo :

$$\frac{\text{Ingresos Técnicos + Naturaleza}}{\text{Activo Total}}$$

3.- Solvencia :

$$\frac{\text{Pasivo Total}}{\text{Activo Total}}$$

4.- Endeudamiento Patrimonial :

$$\frac{\text{Pasivo Total}}{\text{Patrimonio}}$$

5.- Rentabilidad de Capital (%) :

$$\frac{\text{Utilidad Neta}}{\text{Capital Social}} * 100$$

6.- Rentabilidad Patrimonial (%) :

$$\frac{\text{Utilidad Neta}}{\text{Patrimonio}} * 100$$

7.- Valor en Libros (%) :

$$\frac{\text{Patrimonio}}{\text{Capital Social}} * 100$$

## **INDUSTRIALES, MINERAS Y OTROS SECTORES**

**1.- Razón Corriente :**

$$\frac{\text{Activo Corriente}}{\text{Pasivo Corriente}}$$

**2.- Rotación de Activo :**

$$\frac{\text{Ventas Netas}}{\text{Activo Total}}$$

**3.- Solvencia :**

$$\frac{\text{Pasivo Total}}{\text{Activo Total}}$$

**4.- Endeudamiento Patrimonial :**

$$\frac{\text{Pasivo Total}}{\text{Patrimonio}}$$

**5.- Rentabilidad de Ventas Netas :**

$$\frac{\text{Utilidad Neta}}{\text{Ventas Netas}} * 100$$

**6.- Rentabilidad Patrimonial (%) :**

$$\frac{\text{Utilidad Neta}}{\text{Patrimonio}} * 100$$

**7.- Valor en Libros :**

$$\frac{\text{Patrimonio}}{\text{Capital Social + Acciones de Inversión}} * 100$$