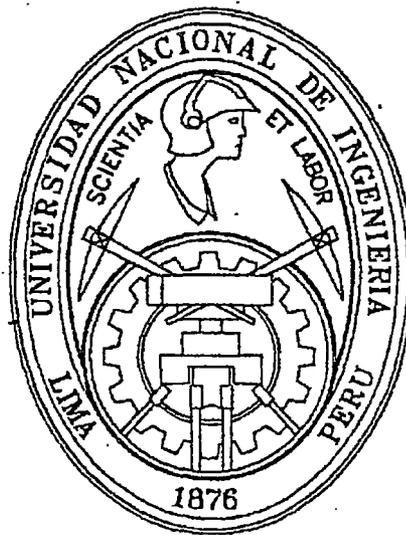


# UNIVERSIDAD NACIONAL DE INGENIERÍA

FACULTAD DE INGENIERIA INDUSTRIAL Y SISTEMAS

SECCIÓN DE POSTGRADO



**“MODELO DE RED NEURONAL RECURRENTE EN LA PREDICCIÓN DE LAS  
VARIABLES ESTRATÉGICAS DE MARKETING Y VENTA DE LA INDUSTRIA  
DE PANIFICACIÓN”**

**TESIS**

**PARA OPTAR EL GRADO ACADÉMICO DE :  
MAESTRO EN CIENCIAS CON MENCIÓN EN  
INGENIERÍA DE SISTEMAS**

**Ing° Ezzard Omar Álvarez Díaz**

**Lima – Perú**

**Digitalizado por:**

**2010**

**Consortio Digital del  
Conocimiento MebLatam,  
Hemisferio y Dalse**

## **DEDICATORIA**

El presente trabajo de investigación para optar el grado académico de Magister en Ingeniería de Sistemas lo dedico con todo mi amor a mi esposa Gladis y a mi hijo Fritz, mis dos amores que dan sentido a mi vida a la vez que la hacen divertida y significativa. Su amor ha sido el factor estabilizador y motivador que es y ha estado siempre presente a pesar de las horas que les he robado, independientemente de las circunstancias.

## **AGRADECIMIENTOS**

Agradezco infinitamente a Dios por la paciencia y esperanza que me concede en cada momento de mi vida; y tengo la certeza de que me extiende la mano cuando más lo necesito.

Cualquier agradecimiento que expresaría hacia todos aquellos que me han estado ayudando en el transcurso de los años sería superficial e insuficiente. Sin embargo, algunos han contribuido en tal grado que sus nombres literalmente sobresalen en las páginas de mi vida y sus nombres exigen reconocimientos.

A mi padre, Fortunato quien a través de sus vivos ejemplos de fe, valor, serenidad, sentido común y amor, me dio los principios de la vida. A mi madre Vilma, por su amor y vida dedicada a forjar herederos que bajo la voluntad de Dios estén al servicio de los que más lo necesitan, y por su fortaleza ante la tempestad de los problemas.

El eterno agradecimiento a mi hermano Ossian quien me brindo el apoyo incondicional desde el principio para seguir los estudios de la Maestría y que

a pesar de la distancia siempre estuvo atento para saber cómo iba mi proceso.

Mil gracias por todas las muestras de cariño a mis hermanos Milton, Ennis, Ana, Karina y Milka que a pesar de la distancia, me dieron ánimo, apoyo y alegría, sin importar la razón y circunstancia; lo que me dio la fortaleza necesaria para seguir adelante.

Al Mg. Luis Miguel Sierra Flores que desempeñó un papel muy importante en este trabajo, por su respuesta rápida en el proceso de desarrollo, por sus aportes, en calidad de asesor.

Al Dr. Pedro Espinoza Haro, como jurado revisor, que por sus directivas y recomendaciones hicieron que este trabajo esté dentro del marco científico.

A la Dr. Daniel Ortega Loayza, como jurado revisor y por su apoyo incondicional en el proceso del desarrollo de esta investigación.

## ÍNDICE

DEDICATORIA.....	ii
AGRADECIMIENTOS .....	iii
ÍNDICE.....	v
DESCRIPTORES TEMATICOS .....	viii
RESUMEN .....	ix
INTRODUCCIÓN .....	1
CAPITULO I.....	3
PLANTEAMIENTO DE LA INVESTIGACIÓN .....	3
1.1. DIAGNOSTICO Y ENUNCIADO EL PROBLEMA.....	3
1.2. DEFINICIÓN DEL PROBLEMA DE INVESTIGACIÓN .....	7
1.2.1. SUB PROBLEMAS .....	7
1.3. DELIMITACIÓN DE LOS OBJETIVOS .....	8
1.3.1 OBJETIVO GENERAL.....	8
1.3.2 OBJETIVOS ESPECÍFICOS .....	8
1.4 HIPOTESIS DE LA INVESTIGACIÓN .....	9
1.4.1 HIPÓTESIS GENERAL .....	9

1.4.2 HIPÓTESIS ESPECÍFICAS.....	9
1.5 JUSTIFICACIÓN DE LA INVESTIGACIÓN .....	9
CAPITULO II .....	12
FUNDAMENTO TEÓRICO.....	12
2.1 ANTECEDENTES DE LA INVESTIGACIÓN .....	12
2.2 MARCO TEÓRICO.....	13
2.2.1 FUNDAMENTOS DE REDES NEURONALES ARTIFICIALES...	13
2.2.2 REDES NEURONALES RECURRENTE.....	28
2.2.3 PRONÓSTICO DE MARKETING Y VENTAS.....	36
2.2.4 TEORÍA DE SERIES DE TIEMPO .....	44
2.2.5 REGRESIÓN LINEAL .....	54
CAPITULO III .....	60
METODOLOGÍA DE LA INVESTIGACIÓN.....	60
3.1 TIPO DE INVESTIGACIÓN .....	60
3.2 DISEÑO DE LA INVESTIGACIÓN.....	61
3.3 ESQUEMA DEL DISEÑO DE INVESTIGACIÓN .....	61
3.4 POBLACIÓN Y MUESTRA.....	62
3.5 VARIABLES E INDICADORES .....	62
3.5.1 VARIABLE INDEPENDIENTE: MODELOS DE PRONÓSTICO ..	62
3.6 TECNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS...	63
3.6.1 TECNICAS DE INVESTIGACIÓN.....	63
3.6.2 INSTRUMENTOS DE RECOLECCIÓN DE DATOS.....	64
CAPITULO IV.....	66
ANÁLISIS E INTERPRETACIÓN DE LOS RESULTADOS DEL	
PRONÓSTICO DE LAS VARIABLES DE MARKETING Y VENTAS.....	66
4.1 DESCRIPCIÓN DE LAS VARIABLES DE PRONÓSTICO.....	66
4.1.1 DESCRIPCIÓN DE LAS VARIABLES:.....	66

4.1.2 DESCRIPCION DE LA DATA HISTÓRICA DE LAS VARIABLES DE ESTUDIO.....	68
4.2 PRONÓSTICO CON SERIES DE TIEMPO .....	70
4.3 PRONÓSTICO CON REGRESIÓN LINEAL .....	72
4.4 PRONOSTICO CON RNA RECURRENTE .....	75
4.4.1 ARQUITECTURA DE ELMAN DE LA RNA RECURRENTE PARA PRONÓSTICO .....	75
4.4.2. ARQUITECTURA PERCEPTRON MULTICAPA DE LA RNA RECURRENTE PARA PRONÓSTICO .....	85
4.5 IMPLEMENTACIÓN DE LOS MODELOS DE PRONÓSTICO PARA LA TOMA DE DECISIONES.....	89
4.5.1 MODELO ESTADÍSTICO DE SERIES DE TIEMPO .....	89
4.5.2 MODELO DE RNA RECURRENTE SERIES DE TIEMPO .....	94
4.5.3 FACTIBILIDAD DE IMPLEMENTACIÓN DEL MODELO DE PRONÓSTICO .....	96
4.6 CONTRASTACIÓN DE LA HIPOTESIS .....	97
CONCLUSIONES Y RECOMENDACIONES.....	99
GLOSARIO DE TERMINOS.....	103
REFERENCIAS BIBLIOGRÁFICA .....	107
ANEXO .....	114

## **DESCRIPTORES TEMATICOS**

1. Redes Neuronales Recurrentes
2. Pronostico de Ventas y Marketing
3. Series de Tiempo
4. Regresión Lineal
5. Neuro solutions

## **RESUMEN**

El presente trabajo de investigación tiene como objetivo principal el de establecer el grado de precisión del Modelo de Red Neuronal Recurrente en la predicción del comportamiento futuro de las variables estratégicas de Marketing y Ventas de la industria de panificación y a la vez de compararlo con los modelos estadísticos de series de tiempo y regresión lineal.

El tipo de investigación es aplicada, porque se construye un modelo de RNA recurrente para las variables de Marketing y Ventas de la industria de panificación. Es experimental porque habrá manipulación de la variable independiente que son los modelos de predicción para observar la precisión en sus pronósticos de las variables de marketing y ventas.

Se concluye que la arquitectura de una RNA recurrente simple es la que se ajusta con mayor precisión al comportamiento de las variables de marketing y ventas frente a la arquitectura genérica de una RNA recurrente.

Además, al hacer pronóstico con los métodos estadísticos de series de tiempo y regresión lineal, se obtiene un error el cual una vez obtenido ya no es posible reducir dicho error. Sin embargo las RNA recurrentes logran reducir el margen de error a un mínimo a medida que se hacen más iteraciones de entrenamiento.

Finalmente, se propone las fichas de documentación que ayudan a implementar estos modelos de pronóstico y así distribuir los roles que permiten obtener los reportes para la toma de decisiones.

## **INTRODUCCIÓN**

El objetivo de este trabajo de investigación fue establecer el grado de precisión del Modelo de Red Neuronal Recurrente en la predicción del comportamiento futuro de las variables estratégicas de Marketing y Ventas de la industria de panificación, y a la vez compararlo con los modelos estadísticos de series de tiempo y regresión lineal.

Para lograr dicho objetivo se ha seguido los siguientes pasos: se inició con el análisis y selección de las variables críticas de éxito de marketing y ventas, luego se diseñó el modelo de red neuronal recurrente asociado al área de marketing y ventas; posteriormente, se validó el modelo red neuronal recurrente asociado al área de marketing y ventas, en seguida se hizo el pronóstico del comportamiento de las variables de marketing y ventas utilizando las técnicas estadísticas, para finalmente comparar la precisión del pronóstico del modelo de red neuronal recurrente con los modelos estadísticos.

El presente trabajo de investigación se ha organizado en cinco capítulos que describimos a continuación.

En el capítulo I se presenta el planteamiento del problema en cinco secciones: que son diagnóstico y enunciado del problema, definición del problema, delimitación de los objetivos, hipótesis y justificación de la investigación.

En el capítulo II, se describe el fundamento teórico divididos en dos partes: Los antecedentes de la investigación y el marco teórico. El marco teórico se ha distribuido en tres partes: fundamentos de redes neuronales artificiales, redes neuronales recurrentes y teoría de pronóstico.

En el capítulo III, se describe la metodología de investigación estructurado en seis secciones: tipo de investigación, diseño, esquema, población, variables y técnicas de investigación.

En el capítulo IV, se presenta el análisis y la interpretación de los resultados organizados en cinco secciones: descripción de las variables de estudio, pronóstico con series de tiempo, pronóstico con regresión lineal, pronóstico con RNA recurrentes e implementación de los modelos de predicción.

Finalmente, en el capítulo V se presenta las conclusiones y recomendaciones del trabajo de investigación.

**Álvarez Díaz, Ezzard Omar**

# **CAPITULO I**

## **PLANTEAMIENTO DE LA INVESTIGACIÓN**

### **1.1. DIAGNOSTICO Y ENUNCIADO EL PROBLEMA**

Stoner (1996) afirma que todas las funciones administrativas, planificación, organización, dirección y control, dependen de un flujo constante de información en cuanto a lo que está pasando en una organización y más allá de ella; es decir el comportamiento futuro de las variables estratégicas. Los gerentes de todos los niveles se están apoyando en las técnicas de proyección para tomar decisiones respecto a órdenes de compra así como la cantidad a producir que se define en función a la demanda.

Naturalmente existen diferentes técnicas para predecir o estimar el comportamiento futuro de las variables de marketing y ventas. Dentro de ellas está medir el riesgo de los clientes para otorgarle un cierto monto de crédito, identificar patrones entre las diferentes variables de marketing, venta y productos, etc. Nuestro interés está centrado en estudiar el

comportamiento futuro de las variables de marketing y ventas que es necesario para mantener un stock adecuado y se logre cubrir la demanda de los clientes logrando así mejorar su satisfacción y generar mayor rentabilidad a la empresa.

La elección e implementación de un método adecuado de predicción siempre ha sido un tema de gran importancia para las empresas. Se utilizan las predicciones en las áreas de compras, marketing, ventas, etc. Un error significativo en la predicción de ventas podría dejar a una empresa sin la materia prima o insumos necesarios para su producción, o podría generarle un inventario demasiado grande.

La estimación del comportamiento futuro de algunas variables puede realizarse utilizando diversas técnicas de predicción. Cada una de las técnicas de predicción tiene una aplicación de carácter especial que hace de su selección un problema de decisión influido por diversos factores, como por ejemplo, la validez y disponibilidad de los datos históricos, la precisión deseada de la predicción, el costo del procedimiento, los beneficios del resultado, los periodos futuros que se desee predecir y el tiempo disponible para hacer el estudio entre otros [Sapag Chain, 2000]

En una situación estable la importancia de los pronósticos es menor. Pero a medida que ella crece en dinamismo y complejidad, más necesaria se torna la proyección de las variables del mercado.

Existen varias técnicas clásicas de proyección. Una forma de clasificarlas consiste en hacerlo en función de su carácter, esto es, aplicando

métodos de carácter cualitativo, modelos causales y modelos de series de tiempo.

Los métodos de carácter cualitativo se basan principalmente en opiniones de expertos como es el método Delphi. Su uso es frecuente cuando el tiempo para elaborar el pronóstico es escaso, cuando no se dispone de todos los antecedentes mínimos necesarios o cuando los datos disponibles no son confiables para predecir el comportamiento futuro.

Los modelos de pronóstico causales parten del supuesto de que el grado de influencia de las variables que afectan al comportamiento del mercado permanece estable, para luego construir un modelo que relacione ese comportamiento con las variables que se estima que son las causantes de los cambios que se observan en el mercado [Dervitsiotis, 1981].

Los modelos de series de tiempo (método estadístico) se refiere a la medición de valores de una variable en el tiempo a intervalos espaciados uniformemente. El objetivo de la identificación de la información histórica es determinar un patrón básico en su comportamiento, que posibilite la proyección futura de la variable deseada.

Existen, además de los métodos clásicos de proyección, diversos métodos de proyección no tradicionales, dentro de los cuales se encuentran las redes neuronales. Debido a su constitución y a sus fundamentos, las redes neuronales artificiales presentan un gran número de características semejantes a las del cerebro humano. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos

anteriores a nuevos casos y de abstraer características esenciales a partir de entradas que representan información irrelevante [José R. Hilera y Víctor J. Martínez, 1995].

Entonces existe un problema a resolver que es el de buscar el modelo o la técnica adecuada que tenga mayor precisión en la estimación futura de las variables estratégicas de marketing y ventas del sector de panificación de tal forma que genere confianza en la toma de decisiones.

Por otra parte, Productos Unión (PU) es un Centro de Aplicación de la Universidad Peruana Unión (UPeU). Es una industria que pertenece al rubro de la panificación, con más de 85 años de existencia y presencia en los hogares del Perú, reconocida por los peruanos como la industria que se preocupa por la salud familiar pues ofrece productos "Saludables por naturaleza".

Niño de Guzmán (entrevista personal enero 10, 2007) menciona que los productos líderes son los de la línea de integrales, apoyado en informes emitidos por los supervisores de los diferentes canales de ventas; además, PU tiene presencia en todas las cadenas de supermercados, principales bodegas y autoservicios a nivel nacional. Esto ha originado que PU busque afianzarse en un mercado cambiante y altamente competitivo.

Con el propósito de enfrentar los cambios del mercado y lograr un posicionamiento, una de las estrategias de PU fue la adquisición de una maquinaria que ha permitido la reducción de tres horas en una de sus líneas de producción, además de otras maquinarias con tecnologías

actuales. Sin embargo, actualmente realizan actividades como la gestión de costos y órdenes de producción, entre otras, en hojas de cálculo utilizando muchas fórmulas de manera manual. También ocurre que no se puede pronosticar con exactitud el volumen de ventas, y por ende, la rentabilidad de ellas, lo cual, en muchas ocasiones, es información requerida con suma urgencia. Dichos procedimientos actuales no permiten que se puedan tomar decisiones financieras y de corrección en cuanto a la disminución o incremento de las órdenes de producción para el volumen de ventas esperado.

El desconocimiento de la empresa de cuánto podría vender en un determinado periodo, con seguridad perjudica los resultados, aún teniendo buenos niveles de venta

## **1.2. DEFINICIÓN DEL PROBLEMA DE INVESTIGACIÓN**

En efecto formulamos la siguiente interrogante:

¿En qué medida, el Modelo de Red Neuronal Recurrente, mejora la precisión de la predicción del comportamiento futuro de las variables estratégicas de Marketing y Ventas de la industria de panificación?

### **1.2.1. SUB PROBLEMAS**

- ¿En qué medida el Modelo de Red Neuronal Recurrente frente a las Técnicas de Series de Tiempo mejora la precisión de la predicción del comportamiento futuro de las variables estratégicas de Marketing y Ventas de la industria de panificación?

- ¿En qué medida el Modelo de Red Neuronal Recurrente frente a la Técnica de Regresión Lineal mejora la precisión de la predicción del comportamiento futuro de las variables estratégicas de Marketing y Ventas de la industria de panificación?

### **1.3. DELIMITACIÓN DE LOS OBJETIVOS**

#### **1.3.1 OBJETIVO GENERAL**

Establecer el grado de precisión del Modelo de Red Neuronal Recurrente en la predicción del comportamiento futuro de las variables estratégicas de Marketing y Ventas de la industria de panificación.

#### **1.3.2 OBJETIVOS ESPECÍFICOS**

1. Definir las variables críticas de Marketing y Ventas para pronosticar.
2. Diseñar el Modelo de Redes Neuronales Artificiales Recurrentes que predice las variables críticas de Marketing y Ventas de la Industria de Panificación.
3. Entrenar y validar el Modelo de Redes Neuronales Artificiales Recurrentes que predice las variables críticas de Marketing y Ventas.
4. Aplicar el modelo para analizar el comportamiento futuro de las variables críticas de Marketing y Ventas.
5. Comparar el modelo de redes neuronales con las técnicas estadísticas.

## **1.4 HIPOTESIS DE LA INVESTIGACIÓN**

### **1.4.1 HIPÓTESIS GENERAL**

El Modelo de Redes Neuronales Artificiales Recurrentes tiene mayor precisión en la Predicción frente a las técnicas estadísticas aplicadas a las variables estratégicas de Marketing y Ventas de la Industria de Panificación.

### **1.4.2 HIPÓTESIS ESPECÍFICAS**

- El Modelo de Redes Neuronales Artificiales Recurrentes tiene mayor precisión frente a las Técnicas de Series de Tiempo en el pronóstico de las variables estratégicas de Marketing y Ventas de la Industria de Panificación.
- El Modelo de Redes Neuronales Artificiales Recurrentes tiene mayor precisión frente a la Técnica de Regresión Lineal en el pronóstico de las variables estratégicas de Marketing y Ventas de la Industria de Panificación.

## **1.5 JUSTIFICACIÓN DE LA INVESTIGACIÓN**

La presente investigación tiene relevancia y aporta a la ciencia y tecnología con un modelo de red neuronal recurrente ajustado a las variables de marketing y ventas que permita predecir o estimar el comportamiento futuro de dichas variables para la toma de decisiones. Este modelo tendrá las características necesarias para pronosticar el comportamiento futuro de las variables estratégicas de marketing y ventas de la industria de panificación pues su mayor

necesidad es reducir la incertidumbre de la demanda que existe con los productos perecibles que están sujetos al clima estacional.

Por otra parte, en particular, debido a la importancia que tiene el proceso del análisis de rentabilidad en PU, se hace necesario el desarrollo de un modelo de predicción que se utilice para planificar la producción de tal forma que no quede elevados niveles de stocks.

Además, si se tiene estimaciones futuras del comportamiento de ventas, el área de logística externa realizará sus órdenes de compra en el momento preciso y la cantidad adecuada de tal forma que no se tenga elevados niveles de stock de materia prima, logrando así reducir el valor de los inventarios.

Entre otros beneficios resaltantes podemos mencionar:

- Dotar al departamento de marketing y de ventas, una herramienta que ayude en la elaboración del pronóstico.
- Proporcionar valor añadido mediante la inclusión en la base de datos de la información generada por el sistema, de manera que siempre esté disponible, de forma centralizada, aportando mayor seguridad que en la actualidad.
- Será la base de la planeación corporativa a largo plazo.
- Proporcionará la base de la planeación presupuestaria y del control de costos.
- El modelo brindará al usuario una manera cómoda, sencilla, segura y gradual; información de las ventas futuras que se usará para la toma de decisiones.

- Apoyará a la toma de decisiones a las Gerencias de Marketing y Ventas, y Producción al proveerlos con información congruente y exacta.
- Brindará gran flexibilidad en la elaboración de pronósticos y múltiples escenarios para efectos de análisis de ventas proyectadas.
- Apoyará las decisiones del volumen de producción para las ventas mensuales al estimar o pronosticar la demanda de los productos.

## **CAPITULO II**

### **FUNDAMENTO TEÓRICO**

#### **2.1 ANTECEDENTES DE LA INVESTIGACIÓN**

Nojek, Britos, P. Rossi, B. y García Martínez, R. (2003) Pronóstico de Ventas: Comparación de Predicción basada en Redes Neuronales versus Método Estadístico. El objetivo de este trabajo de investigación ha sido estudiar la predicción de ventas mediante el uso de redes neuronales y comparar los resultados obtenidos con los pronósticos de un método estadístico clásico y establecer los entornos más adecuados para su uso. Para este trabajo, se utilizó un software de la empresa J. D. Edwards, el Supliré Relationship Management (SRM). El mismo utiliza doce métodos de pronóstico estadísticos distintos. Y, para el modelo de una red neuronal, se utilizó la estructura de backpropagation para predecir la variable ventas debido a que esta red es especialmente útil en aplicaciones de reconocimiento o clasificación de patrones.

Existen cuatro aspectos que caracterizan una red neuronal: su topología, el mecanismo de aprendizaje, tipo de asociación realizada entre la información de entrada y salida, finalmente, la forma de representación de estas informaciones [José R. Hilera, 1995]. En este trabajo, se estudiaron los resultados obtenidos luego de utilizar cuatro configuraciones de red distintas.

## **2.2 MARCO TEÓRICO**

### **2.2.1 FUNDAMENTOS DE REDES NEURONALES ARTIFICIALES**

#### **2.2.1.1 CONCEPTOS DE LA RED NEURONAL ARTIFICIAL –**

##### **RNA**

Una RNA es un conjunto de nodos ordenados adaptables, los cuales a través de un proceso de aprendizaje mediante ejemplos prototipo, almacenan conocimiento de tipo experimental y lo hacen disponible para su uso. [An Introduction to Neural Computing. Igor Aleksander and Helen Morton, 1990]

Una RNA es un ensamble de elementos procesadores simples y adaptables, cuya funcionalidad está basada en una neurona biológica. La habilidad de procesamiento de la red está almacenada en la intensidad de las conexiones entre elementos, obtenidos por un proceso de adaptación a un conjunto de patrones de entrenamiento.

### 2.2.1.2 ESTRUCTURA DE UNA RED NEURONAL ARTIFICIAL

Los elementos básicos de un sistema neuronal biológico son las neuronas, que se encuentran agrupadas en conjuntos conformados por millones de ellas organizadas en capas, constituyendo un sistema con funcionalidad propia. En la realización de un sistema neuronal artificial puede establecerse una estructura jerárquica similar. El elemento fundamental que dará el comienzo o partida será la neurona artificial; y por último, una red neuronal, con interfaces de entrada y salida, mas los módulos convencionales adicionales necesarios que darán un sistema general de todo el proceso.

Existen tres conceptos fundamentales en la teoría de las redes neuronales que se desea emular en las redes neuronales artificiales, son: paralelismo de cálculo, memoria distribuida y adaptabilidad al entorno.

El **procesamiento paralelo**, es muy importante para el proceso y se puede deducir en un sencillo ejemplo donde una computadora convencional tipo PC, que trabaja secuencialmente instrucción a instrucción, emplearía varios minutos en realizar sobre una imagen compuesta por, digamos 256x256 píxeles, una sencilla tarea de tratamiento en bajo nivel (acentuar contrastes, extraer contornos, etc.), mucho más simple que la que llevaba a

cabo el sistema visual para reconocer una imagen, operando en paralelo, puesto que cada uno podría operar en paralelo sobre diferentes sectores de la imagen, el cerebro humano tarda aproximadamente el mismo tiempo en procesar pero con la diferencia que la imagen esta compuesta por millones de píxeles (los que representan los conos y bastones de la retina), extraer sus rasgos característicos, analizarlas, e interpretarla. Ningún sistema creado por el hombre es capaz de realizar algo semejante. El secreto se encuentra en éste último, donde miles de millones de neuronas que intervienen en el proceso de visión están operando en paralelo sobre la totalidad de la imagen.

La **memoria distribuida**, mientras que en una computadora la información ocupa posiciones de memoria bien establecidas, en los sistemas neuronales se encuentra distribuida por las sinapsis de la red, de modo que si una sinapsis resulta dañada, no perderemos más que una parte muy pequeña de la información. Además, los sistemas neuronales biológicos son redundantes, de modo que muchas neuronas y sinapsis pueden realizar un papel similar; en definitiva el sistema resulta tolerante a fallos (por ejemplo, cada día mueren miles de neuronas en nuestro cerebro y sin embargo tienen que pasar

muchos años para que se resientan nuestras capacidades).

El último concepto fundamental es el de **adaptabilidad** las redes neuronales artificiales se adaptan fácilmente al entorno modificando sus sinapsis y aprenden de la experiencia, pudiendo generalizar conceptos a partir de casos particulares.

### 2.2.1.3 MODELO GENERAL DE UNA NEURONA ARTIFICIAL

Se denomina *procesador elemental* o *neurona artificial* aun dispositivo simple de cálculo que, a partir de un vector de entrada procedente del exterior o de otras neuronas, proporciona una única respuesta o salida. Sus elementos son los siguientes:

- Conjunto de **entradas**,  $x_j(t)$ .
- **Pesos sinápticos** de la neurona  $i$ ,  $w_{ij}$  que presentan la intensidad de interacción entre cada neurona presináptica  $j$  y la neurona postsináptica  $i$ .
- **Regla de propagación**  $\sigma(w_{ij}, x_j(t))$ , que proporciona el valor del potencial postsináptico  $h_i(t) = \sigma(w_{ij}, x_j(t))$ , de la neurona  $i$ , en función de sus pesos y entradas.

$$\sigma(w_{ij}, x_j(t)) = \sum_{j=1}^n w_{ij} \cdot x_j(t) + \theta$$

- **Función de Activación:**  $f_i(a_i(t-1), h_i(t))$ , que proporciona el estado de activación actual  $a_i(t) = f_i(a_i(t-1), h_i(t))$ , de la neurona  $i$ , en función de su estado anterior  $a_i(t-1) = f_i(a_i(t-2), h_i(t-1))$ , y de su potencial postsináptico actual.
- **Función de salida**  $F_i(a_i(t))$ , que proporciona la salida actual  $y_i(t) = F_i(a_i(t))$ , de la neurona  $i$ , en función de su estado de activación.

De este modo, la operación de la neurona  $i$  puede expresarse como

$$y_i(t) = F_i(f_i(a_i(t-1), \sigma_i(w_{ij}, x_j(t))))$$

Este modelo de neurona artificial es la inspiración de la neurona biológica, en el sentido de integrar una serie de entradas y proporcionar cierta respuesta, que se propaga por el axón.

#### 2.2.1.4 ENTRADAS Y SALIDAS

Las variables de entrada y salida pueden ser binarias (digitales) o continuas (analógicas) dependiendo del modelo de aplicación. Dependiendo del tipo de salida, las neuronas suelen recibir nombres específicos como las siguientes:

- **Neurona de tipo McCulloch-Pitts:** Cuyas salidas sólo pueden tomar valores de 0 ó 1.

- **Neurona de tipo Ising:** Cuya salidas únicamente pueden tomar valores de -1 ó +1
- **Neurona de tipo Potts:** Cuya salidas se encuentran dentro de un intervalo continuo de: [0, +1] o [-1, +1].

### A. Regla de Propagación

La regla de propagación permite obtener, a partir de las entradas y los pesos, el valor del potencial postsináptico  $h_i$  de una neurona.

$$h_i(t) = \sigma(w_{ij}, x_j(t))$$

La función más habitual es de tipo lineal, y se basa en la suma ponderada de las entradas con los pesos sinápticos

$$h_i(t) = \sum_j w_{ij} x_j + \theta_i$$

Que formalmente, también se puede expresar como el producto escalar de los vectores de entrada y salida.

### B. El Peso Sináptico

Los pesos sinápticos  $w_{ij}$ . Al igual que en una neurona biológica se establecen sinapsis entre las dendritas de una neurona y el axón de otra, en una neurona artificial a las entradas que vienen de otras neuronas se les asigna un peso, un factor de importancia. Este peso, que es un número, se modifica durante el entrenamiento de la red neuronal, y es aquí por tanto donde se almacena la

información que hará que la red sirva para un propósito u otro.

En la figura 2.1 se muestra el modelo de una Red Neuronal Artificial.

### Modelo de una Red Neuronal Artificial

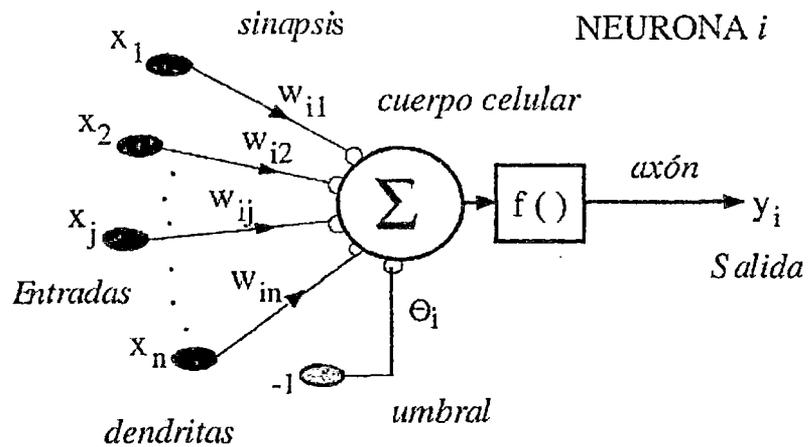


Figura 2.1. Modelo de una Red Neuronal Artificial.

Donde:

Vector  $\mathbf{X}$  ( $x_1, x_2, \dots, x_N$ ) de entradas y produce un salida única  $Y_i$

Pesos y funciones sinápticas  $w_{ij}; \theta$

Función: 
$$y_i = f\left(\sum_j w_{ij} x_j - \theta_i\right)$$

Salida: 
$$f\left(\sum_j w_{ij} x_j - \theta_i\right)$$

Entonces: 
$$y = f\left(\sum_j w_{ij} * x_j - \theta_i\right)$$

Las señales de entrada y salida pueden ser señales binarias (0,1 – neuronas de McCulloch y Pitts), bipolares

(-1,1), números enteros o continuos, variables borrosas, etc.

La regla de propagación suele ser una suma ponderada del producto escalar del vector de entrada y el vector de pesos:

$$h_i(t) = \sum w_{ij} x_j - \theta$$

### 2.2.1.5 FUNCIÓN DE ACTIVACIÓN O FUNCIÓN DE TRANSFERENCIA

La función de activación suele no tener en cuenta el estado anterior de la neurona, sino sólo el potencial  $h_i(t) = \sigma(w_{ij}, x_j(t))$ . Suele ser una función determinista y, casi siempre, continua y monótona creciente. Las más comunes son la función signo, la función semilineal y las funciones sigmoides. En la figura 2.2 se muestra las principales funciones de transferencia.

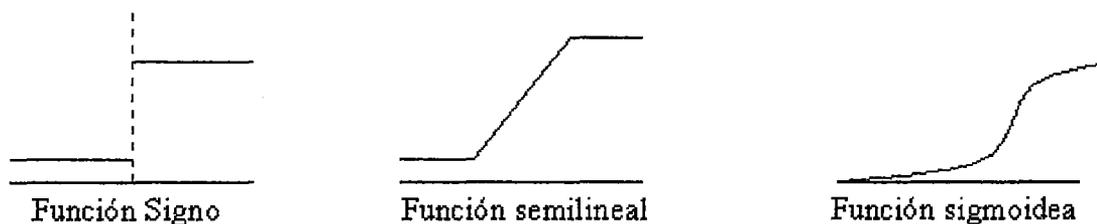


Figura 2.2 Principales Funciones de Transferencia

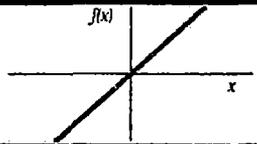
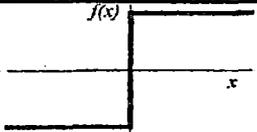
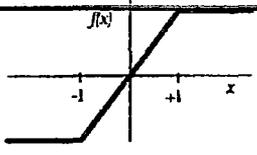
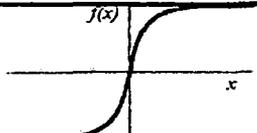
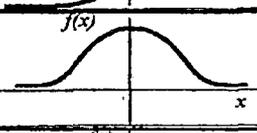
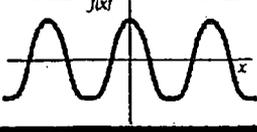
En ocasiones los algoritmos de aprendizaje requieren que la función de activación cumpla la condición de ser derivable.

Las más empleadas en este sentido son las funciones de tipo sigmoideo. Otra función clásica es la Gaussiana, que

se utiliza junto con reglas de propagación que involucran el cálculo de cuadrados de distancias (por ejemplo, la Euclídea) entre los vectores de entrada y pesos.

Por último en ocasiones se emplean funciones sinusoidales como aquellos casos en los que se requiere expresar explícitamente una periodicidad temporal.

### Funciones de Activación

	Función	Rango	Gráfica
<b>Identidad</b>	$y = x$	$[-\infty, +\infty]$	
<b>Escalón</b>	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
<b>Lineal a tramos</b>	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq l \\ +1, & \text{si } x > l \end{cases}$	$[-1, +1]$	
<b>Sigmoidea</b>	$y = \frac{1}{1+e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
<b>Gaussiana</b>	$y = Ae^{-Bx^2}$	$[0, +1]$	
<b>Sinusoidal</b>	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

Cuadro 2.1 Funciones de activación habituales donde se han omitido algunas constantes

#### 2.2.1.6 ARQUITECTURA DE LAS RNA

La arquitectura de una RNA es la estructura o patrón de conexiones de la red. Es conveniente recordar que las

conexiones sinápticas son direccionales, es decir, la información sólo se transmite en un sentido.

En general, las neuronas suelen agruparse en unidades estructurales llamadas *capas*. Dentro de una capa, las neuronas suelen ser del mismo tipo. Se pueden distinguir tres tipos de capas:

- ❖ De *entrada*: reciben datos o señales procedentes del entorno.
- ❖ De *salida*: proporcionan la respuesta de la red a los estímulos de la entrada.
- ❖ *Ocultas*: no reciben ni suministran información al entorno (procesamiento interno de la red).

Generalmente las conexiones se realizan entre neuronas de distintas capas, pero puede haber conexiones intracapa o *laterales* y conexiones de *realimentación* que siguen un sentido contrario al de entrada-salida. En la figura 2.3 se presenta la arquitectura de una RNA.

### Arquitectura de una RNA

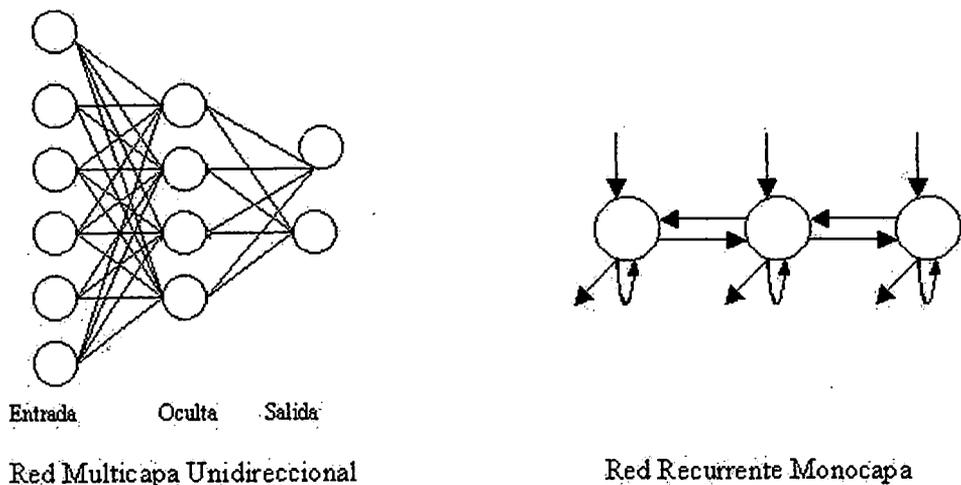


Figura 2.3 Arquitectura de una RNA

### 2.2.1.7 APRENDIZAJE DE LAS RNA

Es el proceso por el que una RNA actualiza los pesos (y, en algunos casos, la arquitectura) con el propósito de que la red pueda llevar a cabo de forma efectiva una tarea determinada. Hay tres conceptos fundamentales en el aprendizaje:

**Paradigma de aprendizaje:** información de la que dispone la red.

**Regla de aprendizaje:** principios que gobiernan el aprendizaje.

**Algoritmo de aprendizaje:** procedimiento numérico de ajuste de los pesos.

Existen dos paradigmas fundamentales de aprendizaje:

**Supervisado:** la red trata de minimizar un error entre la salida que calcula y la salida deseada (conocida), de modo que la salida calculada termine siendo la deseada.

**No supervisado o autoorganizado:** la red conoce un conjunto de patrones sin conocer la respuesta deseada. Debe extraer rasgos o agrupar patrones similares.

En cuanto a los algoritmos de aprendizaje, tenemos cuatro tipos:

**Minimización del error:** reducción del gradiente, retropropagación, etc. La modificación de pesos está orientada a que el error cometido sea mínimo.

**Boltzmann:** Para redes estocásticas, donde se contemplan parámetros aleatorios.

**Hebb:** Cuando el disparo de una célula activa otra, el peso de la conexión entre ambas tiende a reforzarse (Ley de Hebb).

**Competitivo:** Sólo aprenden las neuronas que se acercan más a la salida deseada.

Los algoritmos, y en general el proceso de aprendizaje, son complejos y suelen llevar bastante tiempo computacionalmente hablando. Su ventaja es que una vez ha aprendido, la red puede congelar sus pesos y funcionar en modo *recuerdo* o *ejecución*.

Teniendo en cuenta la teoría podemos distinguir tres niveles de arquitectura:

- **Microestructura.** Hace referencia a los elementos más pequeños de las redes neuronales: las neuronas.
- **Mesoestructura.** Resultado de la combinación de las neuronas. Serían las redes neuronales propiamente dichas.
- **Macroestructura.** Combinación de redes, se podría denominar a este nivel "comité de expertos". Existen diferentes tipos de combinación: paralelo, jerárquica, etc. dependiendo de la aplicación que se quiera implementar.

### 2.2.1.8 MICRO ESTRUCTURA

Es el elemento básico de la red: la neurona, que puede tener diferentes formas dependiendo de la aplicación. En la figura 2.4 se presenta un esquema básico:

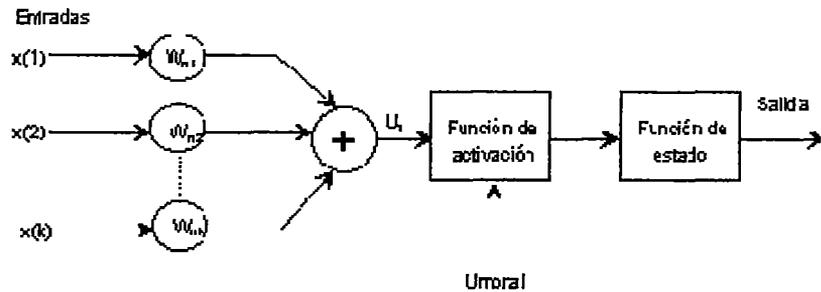


Figura 2.4 - Esquema de una neurona.

En general una neurona tendrá los siguientes elementos:

- **Entradas.** Son los datos a utilizar por la neurona. Pueden ser las variables de entrada, si la neurona está en la capa de entrada del sistema, o las salidas de otras neuronas. Si alguna de las entradas a la neurona es una salida de dicha neurona estaríamos hablando de una neurona recurrente o con memoria.
- **Conexiones.** Denominados pesos en teoría de redes neuronales. Son los factores multiplicativos de las entradas. Existe un peso adicional denominado umbral que tiene como entrada 1. El significado de este peso es englobar el umbral que aparece en la figura 1. Este umbral define el valor para el cual la neurona se activa, es decir:

$$\text{Neurona} \begin{cases} \text{activa si } w_1 \cdot x_1 + \dots + w_n \cdot x_n > \text{umbral} \\ \text{inactiva si } w_1 \cdot x_1 + \dots + w_n \cdot x_n < \text{umbral} \end{cases}$$

Si tomamos el peso  $w_0$  como  $-\text{umbral}$  entonces la anterior expresión queda como:

$$\text{Neurona} \begin{cases} \text{activa si } w_0 + w_1 \cdot x_1 + \dots + w_n \cdot x_n > 0 \\ \text{inactiva si } w_0 + w_1 \cdot x_1 + \dots + w_n \cdot x_n < 0 \end{cases}$$

El proceso de aprendizaje de una red radica en la modificación de estos pesos de acuerdo con un algoritmo determinado.

Si combinamos la estructura de una neurona con una de las funciones de activación más usada, la Sigmoidea, aparece una relación matemática habitualmente utilizada como prueba diagnóstica: la regresión logística. En efecto, este método matemático consiste en modelizar la probabilidad de un determinado evento de acuerdo a la siguiente expresión:

$$P(\vec{x}) = \frac{1}{1 + e^{-w_0 + w_1 x_1 + w_2 x_2 + \dots + w_n x_n}}; \quad \vec{x} = (x_1, x_2, \dots, x_n)$$

Donde  $x_n$  son las diferentes variables independientes de las que depende nuestro problema.

Los parámetros a determinar son los parámetros  $w_n$  que son equivalentes a los pesos de una neurona. Así pues, cuando se utiliza el método de regresión logística se está usando una red constituida por una sola neurona,

evidentemente este modelo tan sencillo se puede mejorar. Al estudiar este modelo, representado por una neurona, se pueden sacar importantes conclusiones. En efecto, el caso más sencillo es clasificar dos grupos (A y B) usando la probabilidad definida por el modelo de regresión logística. En este modelo se define un umbral de tal forma que si el valor de  $P(x)$  es superior a ese umbral pertenece a la clase A y si no a la B. Esta condición se transforma en que el exponente sea mayor que cierta cantidad, es decir:

$$\begin{cases} x \text{ pertenece a la clase A si } w_0 + w_1 \cdot x_1 + \dots + w_n \cdot x_n > K \\ x \text{ pertenece a la clase B si } w_0 + w_1 \cdot x_1 + \dots + w_n \cdot x_n < K \end{cases}$$

Veamos qué significa esto con un caso simple:

supongamos que nuestro problema sólo depende de dos variables, entonces el caso definido anteriormente queda como:

$$\begin{cases} x \text{ pertenece a la clase A si } w_0 + w_1 \cdot x_1 + w_2 \cdot x_2 > K \\ x \text{ pertenece a la clase B si } w_0 + w_1 \cdot x_1 + w_2 \cdot x_2 < K \end{cases}$$

La frontera entre las dos clases vendrá definida por los ejemplos que cumplen la siguiente condición:

$$w_0 + w_1 \cdot x_1 + w_2 \cdot x_2 = K$$

La ecuación anterior es la ecuación de una recta. Por tanto, el modelo de regresión logística sólo permite clasificar correctamente elementos que sean linealmente

separables; se trata de un modelo muy limitado. Se puede aumentar su potencia mediante transformaciones no lineales de las entradas pero se requiere un conocimiento a priori del problema que no siempre se tiene. La manera de mejorar este modelo es combinar estos elementos de proceso en estructuras más grandes: las redes neuronales, pasamos pues a otro nivel: la mesoestructura.

### **2.2.2 REDES NEURONALES RECURRENTE**

Es sabido que las redes neuronales estáticas o prealimentadas son capaces de aproximar cualquier función continua (Cotter, 1990). Sin embargo, las redes neuronales recurrentes poseen un rico repertorio de arquitecturas, lo cual las habilita para realizar diversas aplicaciones, que no son posibles con las redes neuronales estáticas; algunas de estas aplicaciones son: predicción no lineal, modelado, control, representaciones en espacio de estado, etc.

Las redes neuronales recurrentes son aquellas que tienen uno o más lazos de retroalimentación. La retroalimentación puede ser local, es decir que la neurona se retroalimenta a sí misma, o global, cuando la neurona retroalimenta neuronas de la misma capa o de capas anteriores. Una red recurrente responde temporalmente a una señal de entrada externa. Más aún, la retroalimentación habilita a las redes neuronales recurrentes a tener una representación en espacio de estado, lo cual las hace convenientes para diversas aplicaciones.

## 2.2.2.1 ARQUITECTURA DE REDES NEURONALES

### RECURRENTES

Se describirán dos arquitecturas neuronales, todas ellas con retroalimentación global. Las características que poseen en común son:

- Incorporan un perceptrón multicapa o parte de él.
- Explotan las capacidades de la transformación no lineal del perceptrón multicapa.

#### A. Redes neuronales recurrentes entrada-salida

La Figura 2.5 muestra la arquitectura de una red neuronal recurrente genérica, que surge de manera natural de un perceptrón multicapa. El modelo tiene sólo una entrada que es aplicada a la entrada de la red, junto con  $l$  de sus retardos; así mismo se retroalimentan a la entrada de la red  $l$  retardos de la salida  $y(k+1)$ .

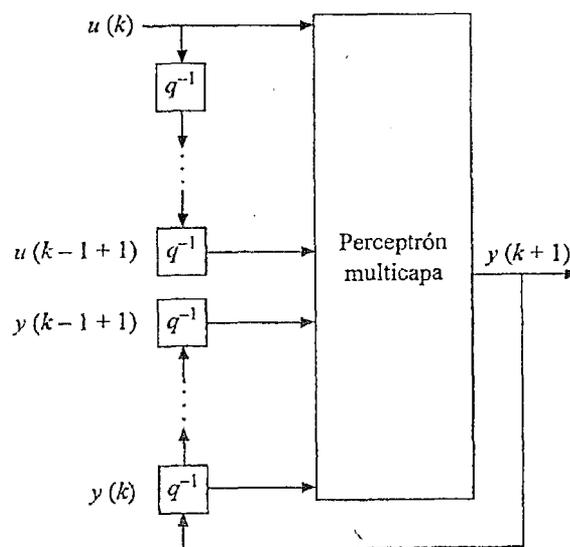


Figura 2.5 – Modelo de Entrada – Salida.

De tal forma que el comportamiento dinámico de la red de la Figura 4 queda determinado por:

$$y(k+1) = F(y(k), \dots, y(k-l+1), u(k), \dots, u(k-l+1))$$

Donde  $F$  es una función no lineal.

### B. Modelo en espacio y estado

La Figura 2.6 muestra un diagrama a bloques de otra red neural recurrente genérica, llamada modelo en espacio de estado. Las neuronas ocultas definen el estado de la red. La Salida de la capa oculta es retroalimentada a la capa de entrada a través de un banco de retardos unitarios. La capa de entrada consiste en la concatenación de los nodos de retroalimentación y los nodos fuente. La red es conectada al medio exterior a través de los nodos fuente. El número de retardos unitarios utilizados en la retroalimentación determina el orden del modelo. Sea  $u(k)$  pertenece a  $R^m$  el vector de entrada, y  $x(k)$  pertenece a  $R^q$  la salida de la capa oculta en la iteración  $k$ .

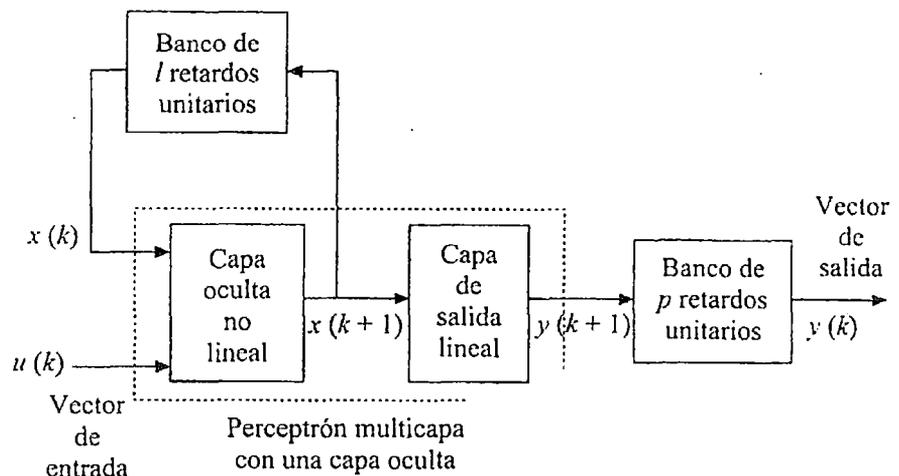


Figura 2.6 – Modelo de Espacio de estado.

Entonces el comportamiento dinámico del modelo de la figura 2.6 queda determinado por  $y$  que pertenece a  $R^q$ :

$$x(k+1) = f(x(k), u(k))$$

$$y = Cx(k)$$

donde  $f(x(k), u(k))$  es una función no lineal que caracteriza a la capa oculta;  $C$  es la matriz de pesos sinápticos que caracterizan a la capa de salida. La capa oculta es no lineal, pero la capa de salida es lineal.

La red neuronal recurrente de la Figura 2.6 incluye algunas arquitecturas recurrentes como casos especiales. Considérese, por ejemplo, la red neuronal recurrente simple mostrada en la Figura 2.7. La red de Elman tiene una arquitectura similar a la de la Figura 2.5 excepto por el hecho de que la capa de salida puede ser no lineal y el banco de retardos unitarios a la salida se omite.

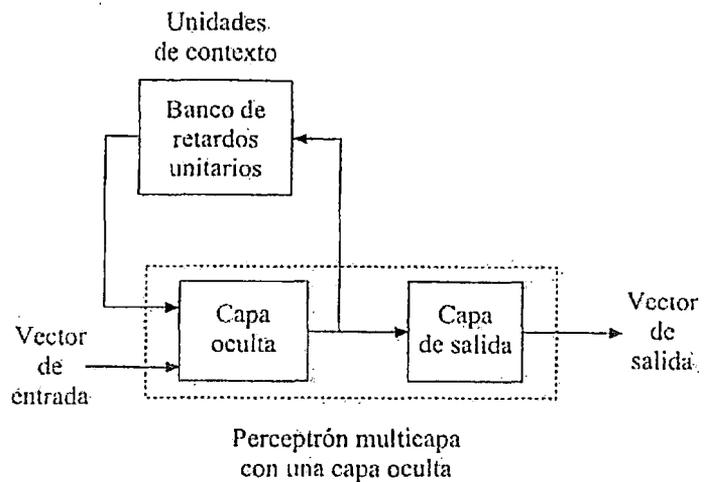


Figura 2.7 – Red Neuronal Recurrente Simple.

La red de Elman (Elman, 1990) contiene conexiones recurrentes de las neuronas ocultas a la capa de unidades contextuales consistente en retardos unitarios. Estas unidades contextuales almacenan las salidas de las neuronas ocultas, lo que les permite desarrollar las tareas de aprendizaje a través del tiempo. Las neuronas ocultas también alimentan a las neuronas de salida. Debido a la naturaleza de la retroalimentación alrededor de las neuronas ocultas, estas neuronas pueden continuar reciclando información a través de la red durante muchos pasos en el tiempo y así obtener representaciones abstractas del tiempo.

#### **2.2.2.2 PERCEPTRÓN MULTICAPA RECURRENTE**

Esta red tiene una o más capas ocultas; básicamente por las mismas razones que el perceptrón multicapa estático, siempre son más efectivas con una sola capa oculta. Cada capa de computación de un RMLP (por su nombre en inglés Recurrent Multilayer Perceptron) tiene retroalimentación alrededor de la misma, como se muestra en la Figura 2.8, para el caso de un RMLP con dos capas ocultas.

Sea el vector  $x_i(k)$  que denota la salida de la primera capa oculta;  $x_{ii}(k)$  denota la salida de la segunda capa oculta, y así sucesivamente;  $x_0(k)$  denota la salida de la capa de

salida. Entonces el comportamiento dinámico del RMLP en respuesta al vector de entrada  $u(k)$  queda determinado por:

$$\begin{aligned}
 x_I(k+1) &= Q_I(x_I(k), u(x)) \\
 x_{II}(k+1) &= Q_{II}(x_{II}(k), x_I(k+1)) \\
 &\vdots \\
 &\vdots \\
 &\vdots \\
 x_o(k+1) &= Q_o(x_o(k), x_n(k+1))
 \end{aligned}$$

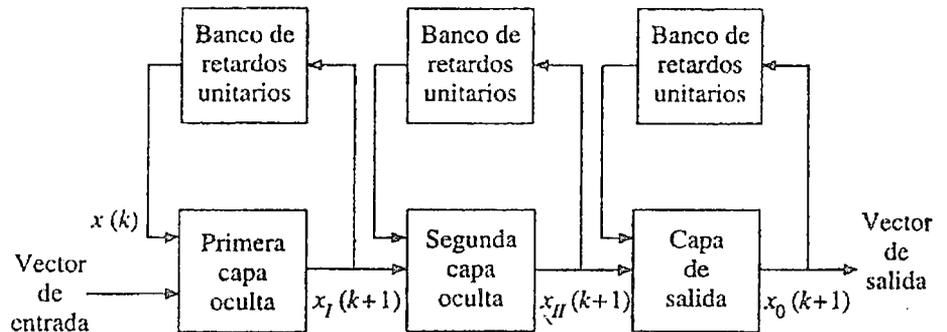


Figura 2.8 – Perceptrón multicapa recurrente.

Donde  $Q_I(\dots)$ ,  $Q_{II}(\dots)$ , ...,  $Q_o(\dots)$  representan las funciones de activación respectivas y denota el número de capas ocultas de la red.

### 2.2.2.3 RED DE SEGUNDO ORDEN

En el modelo en espacio de estado, se utilizó la palabra *orden* para referirse al número de neuronas ocultas cuyas salidas son retroalimentadas a la capa de entrada. En otro contexto, la palabra orden algunas veces es utilizada para referirse a la forma en que se define el potencial de activación de una neurona.

Una característica única de la red neuronal de segundo orden de la Figura 2.9 es que el producto  $x_i(k)u_j(k)$  representa el par {estado, entrada} y que un peso positivo  $w_{n_{ij}}$  representa la presencia de una transición de estado {estado, entrada}  $\rightarrow$  {siguiente estado}, mientras que un peso negativo representa la ausencia de la transición.

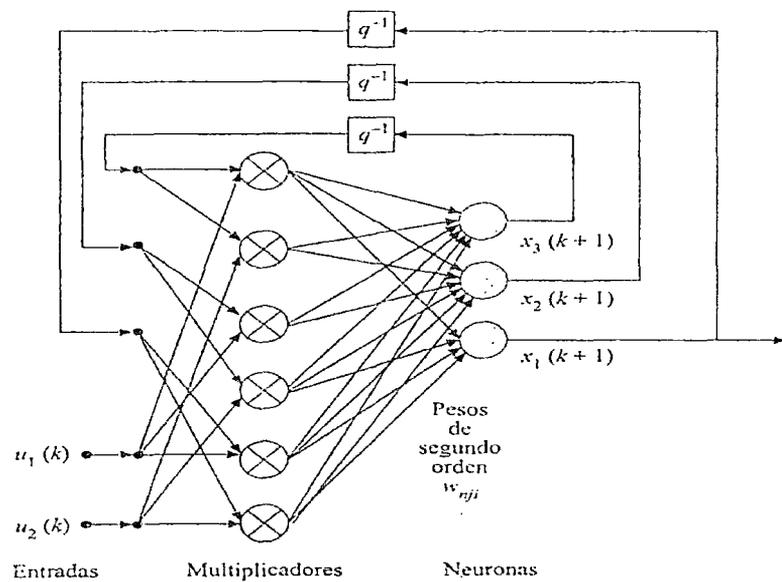


Figura 2.9 – Red Neuronal de segundo orden.

#### 2.2.2.4 REDES NEURONALES RECURRENTE DE ALTO ORDEN

En una RHONN, por su nombre en inglés (Recurrent High Order Neural Networks) como se muestra en la figura 2.10, es posible obtener interacciones de alto orden superando aun a una red neuronal de segundo orden.

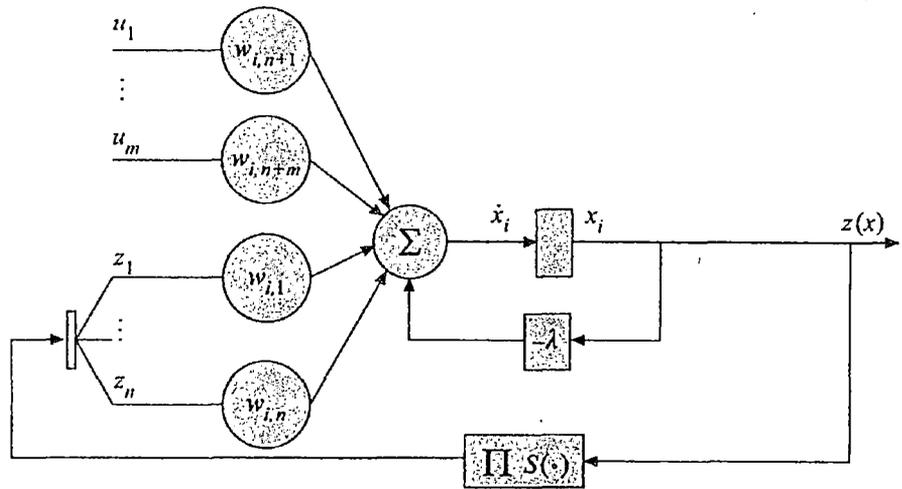


Figura 2.10 – Esquema de una RHONN continua.

Las RHONN tienen las siguientes características (Ricalde, 2005)

- Permiten el modelado eficiente de sistemas dinámicos complejos;
- Son buenos candidatos para identificación y control;
- Son de fácil implementación;
- Su estructura es relativamente sencilla;
- Son capaces de ajustar sus parámetros en línea.

#### 2.2.2.5 REDES NEURONALES RECURRENTE DE ALTO ORDEN DISCRETAS

Las redes neuronales recurrentes de alto orden discretas presentan las mismas características que las continuas y son ideales para su uso en modelado, identificación y control de sistemas dinámicos discretos complejos debido a su facilidad de implementación y a su estructura de relativa sencillez. Ver fig. 2.11

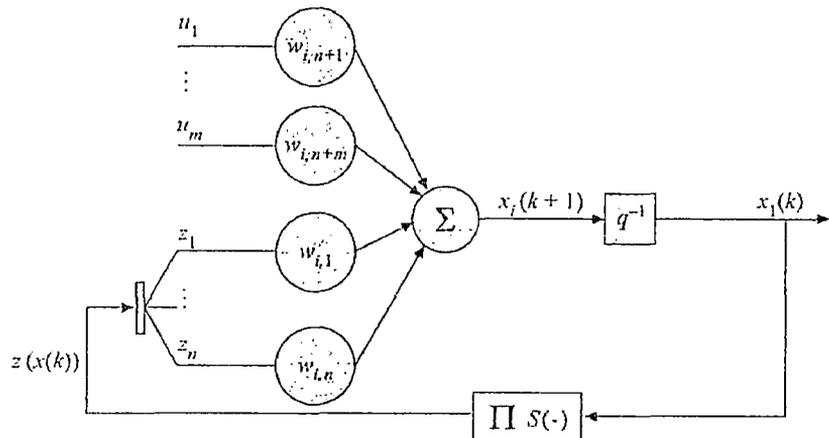


Figura 2.11 – Esquema de una RHONN discreta

### 2.2.3 PRONÓSTICO DE MARKETING Y VENTAS

En todas las empresas, independientemente del tamaño, podemos encontrar preguntas para las cuales no existen respuestas. Una de esas preguntas es: ¿Se preparan pronósticos de ventas?

En general aparecen respuestas afirmativas, pero sin mucho convencimiento, y en muchos otros casos se escucha la excusa que en un mercado tan cambiante no es posible pronosticar nada.

Lo cierto es que no pronosticar cuánto se venderá en el próximo período coloca a la empresa en una posición débil y de incertidumbre.

Si se considera que toda empresa obtiene dinero proveniente de financiamiento externo o bien de sus ventas; prever cuánto ha de venderse es fundamental para conocer si será necesario o no acudir a fuentes de financiamiento.

El desconocer cuánto podría la empresa vender en un determinado período con seguridad perjudica los resultados, aún teniendo buenos niveles de venta. Analicemos algunos casos posibles:

**Se obtienen órdenes de venta por grandes cantidades:**

- Todo aquello que la empresa vende proviene de su propia producción o de compras a proveedores. La venta "no programada" seguramente provocará compras no programadas, diríamos de urgencia. En pocas oportunidades pueden negociarse precios convenientes ante la necesidad de cumplir perentoriamente un compromiso de entrega.
- Quizás las cantidades vendidas no impliquen mayores costos por las compras de mercaderías o materias primas, pero lleva a la empresa a encarar el incremento de la producción y por ende enfrentar decisiones de inversión sin el tiempo suficiente para analizar la forma en que se implementarán.

**No se obtienen buenas órdenes de venta:**

- Cuando se presenta este caso y los ingresos no llegan a ser los suficientes para cubrir las erogaciones del período, la empresa debe salir a buscar fondos con el costo en intereses que esta solución representa.

Es decir, tanto por niveles de venta excelentes o insuficientes, ignorar la posible ocurrencia de los mismos llevará a incrementar los costos y, en definitiva, castigar los resultados.

No sólo éstos son los motivos que generan la necesidad de realizar un pronóstico de ventas. A pesar de que son una predicción siempre sujeta a imprevistos, al momento de tomar decisiones, los directivos de la empresa deberán hacerlo en función de los objetivos fijados a futuro y, uno de ellos es sin duda, la cantidad que será vendida durante un determinado período.

Hasta aquí lo que podemos asegurar es que es necesario conocer el posible nivel de ventas que la empresa tendrá en el próximo período. La pregunta es, ¿cómo podemos imaginar esas cantidades en un mercado tan cambiante como éste?

Llamaremos a este proceso de “imaginar” PROYECTAR las ventas y consideraremos que analizamos períodos equivalentes a un año. Es decir, se proyectarán las ventas del próximo año.

Dos premisas debemos tener presentes: La primera es que en la actualidad todos los mercados son cambiantes, tanto a nivel local como a nivel global. La segunda, debemos considerar que nada puede ser proyectado desde el desconocimiento o la carencia de datos. Es decir, para comenzar debemos basarnos en datos fehacientes.

Las empresas disponen de mucha información con la cual pueden encarar el proceso de proyección:

- Volúmenes históricos de venta, tanto en unidades como en dinero

- Situación de la empresa en períodos anteriores (fuerza de ventas, capacidad de producción, condiciones comerciales, política de crecimiento o supervivencia, etc.)
- Inflación en períodos anteriores
- Condiciones del mercado general en períodos anteriores (recesión, expansión, condicionamientos políticos, etc.)
- Condiciones de su mercado en particular en períodos anteriores (competencia, balanza comercial, tipo de producto ofrecido, hábitos de consumo, etc.)
- Proyecciones económico-sociales para los próximos períodos realizadas por entes confiables (INDEC, Ministerio de Economía, Cámaras, Asociaciones)
- Condiciones de los mercados a futuro (cambio de hábitos de consumo, necesidad de compras repetitivas, entorno social, entorno político)
- Estadísticas públicas
- Publicaciones del sector

Robert Hartley, en su libro "Sales Management" describe el procedimiento de pronosticar dividiéndolo en cinco pasos:

1. Búsqueda de información: Esta información permitirá conocer o todos los factores que influyen en la operatoria de la empresa, pudiéndose o no tener control sobre ellos. Por ejemplo, la empresa no tiene control sobre las decisiones gubernamentales pero sí puede tenerlo sobre sus inversiones.

2. Aplicación de técnicas para pronosticar: Existen técnicas cualitativas y cuantitativas.
3. Llevar el pronóstico de ventas a las operaciones de la empresa: Como ya se dijera anteriormente, las ventas impactan en todos los sectores de la organización y es en función de ellas que cada área deberá ajustarse para funcionar de forma eficiente según el objetivo de ventas fijado.
4. Auditar el pronóstico: Una vez encontrado el objetivo teórico, debe compararse éste con la situación real.
5. Ajustar el pronóstico: En función del paso anterior, quizás sea necesario ajustar el pronóstico o los métodos utilizados para llegar a una proyección más certera.

El pronóstico de ventas tendrá suma importancia en el futuro de la empresa. Una proyección de mayores ventas permitirá evaluar las necesidades de inversión, financiamiento, modificación a las políticas de distribución de ganancias, ampliación de la planta de personal y tantas otras que estarán relacionadas con un objetivo creciente de ventas y por ende de ingresos. En el caso de pronósticos negativos éstos pondrán sobre aviso a los directivos por los inconvenientes que pueden surgir y así podrán tomar acción en tiempo y forma para afrontar la posible baja de ventas pronosticada.

Como vemos, sea cual fuere el resultado del pronóstico, es esencial para tomar decisiones de manera proactiva y así poder

gestionar todos los cambios que la empresa requiera para afrontar el futuro.

### **2.2.3.1 TÉCNICAS PARA DESARROLLAR UNA PROYECCIÓN DE VENTAS**

El pronóstico de ventas difiere del potencial de ventas de la empresa. Este establece lo que serán las ventas reales de la empresa a un determinado grado de esfuerzo de mercadeo de la compañía, mientras que el potencial de ventas evalúa qué ventas son posibles en los diversos niveles del esfuerzo de mercadeo, suponiendo que existan ciertas condiciones del entorno.

Las técnicas generalmente aceptadas para la elaboración de pronósticos se dividen en cinco categorías: juicio ejecutivo, encuestas, análisis de series de tiempo, análisis de regresión y pruebas de mercado. La elección del método o métodos dependerá de los costos involucrados, del propósito del pronóstico, de la confiabilidad y consistencia de los datos históricos de ventas, del tiempo disponible para hacer el pronóstico, del tipo de producto, de las características del mercado, de la disponibilidad de la información necesaria y de la pericia de los encargados de hacer el pronóstico. Lo usual es que las empresas combinen varias técnicas de pronóstico.

### Juicio Ejecutivo

Se basa en la intuición de uno o más ejecutivos experimentados con relación a productos de demanda estable. Su inconveniente es que se basa solamente en el pasado y está influenciado por los hechos recientes.

### Encuesta de Pronóstico de los Clientes

Útil para empresas que tengan pocos clientes. Se les pregunta qué tipo y cantidades de productos se proponen comprar durante un determinado período. Los clientes industriales tienden a dar estimados más precisos. Estas encuestas reflejan las intenciones de compra, pero no las compras reales.

### Encuesta de Pronóstico de la Fuerza de Ventas

Los vendedores estiman las ventas esperadas en sus territorios para un determinado período. La sumatoria de los estimados individuales conforman el pronóstico de la Empresa o de la División. El inconveniente es la tendencia de los vendedores a hacer estimativos muy conservadores que les facilite la obtención futura de comisiones y bonos.

### Análisis de Series de Tiempo

Se utilizan los datos históricos de ventas de la empresa para descubrir tendencias de tipo estacional, cíclico y aleatorio o errático. Es un método efectivo para productos

de demanda razonablemente estable. Por medio de los promedios móviles determinamos primero si hay presente un factor estacional. Con un sistema de regresión lineal simple determinamos la línea de tendencia de los datos para establecer si hay presente un factor cíclico. El factor aleatorio estará presente si podemos atribuir un comportamiento errático a las ventas debido a acontecimientos aleatorios no recurrentes.

#### Análisis de Regresión

Se trata de encontrar una relación entre las ventas históricas (variable dependiente) y una o más variables independientes, como población, ingreso per cápita o producto bruto interno (PBI). Este método puede ser útil cuando se dispone de datos históricos que cubren amplios períodos de tiempo. Es ineficaz para pronosticar las ventas de nuevos productos.

#### Prueba de Mercado

Se pone un producto a disposición de los compradores en uno o varios territorios de prueba. Luego se miden las compras y la respuesta del consumidor a diferentes mezclas de mercadeo. Con base en esta información se proyectan las ventas para unidades geográficas más grandes. Es útil para pronosticar las ventas de nuevos productos o las de productos existentes en nuevos

territorios. Estas pruebas son costosas en tiempo y dinero, además alertan a la competencia.

### **2.2.3.2 ¿CUÁNDO UN MODELO DE PRONÓSTICO ES BUENO?**

- Cuando la Diferencia entre los Datos Entregados por el Modelo No difieren de los Reales.
- Cuando el ERROR es 0 (o está dentro de parámetros aceptables).
- Cuando el Sesgo se mantiene cercano a 0.
- $ERROR = Real - Pronóstico$ .

## **2.2.4 TEORÍA DE SERIES DE TIEMPO**

### **Definición**

(Toledo Muñoz, 1994):

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

### **2.2.4.1 COMPONENTES DE UNA SERIE DE TIEMPO**

**Tendencia secular** (Toledo Muñoz, 1994):

La tendencia secular o tendencia a largo plazo de una serie es por lo común el resultado de factores a largo

plazo. En términos intuitivos, la tendencia de una serie de tiempo caracteriza el patrón gradual y consistente de las variaciones de la propia serie, que se consideran consecuencias de fuerzas persistentes que afectan el crecimiento o la reducción de la misma, tales como: cambios en la población, en las características demográficas de la misma, cambios en los ingresos, en la salud, en el nivel de educación y tecnología. Las tendencias a largo plazo se ajustan a diversos esquemas. Algunas se mueven continuamente hacia arriba, otras declinan, y otras más permanecen igual en un cierto período o intervalo de tiempo.

El método más conocido y también el más usado es el modelo estadístico de regresión lineal, cuya ecuación es:

$$Y = a + bX + e$$

Donde:

Y = Variable dependiente

X = Variable independiente

e= error

a = intercepción con el eje de las abcisas (y)

b = coeficiente de cada variable.

### **Variación estacional**

(Toledo Muñoz, 1994):

El componente de la serie de tiempo que representa la variabilidad en los datos debida a influencias de las estaciones, se llama componente estacional. Esta variación corresponde a los movimientos de la serie que recurren año tras año en los mismos meses (o en los mismos trimestres) del año poco más o menos con la misma intensidad. Por ejemplo: Un fabricante de albercas inflables espera poca actividad de ventas durante los meses de otoño e invierno y tiene ventas máximas en los de primavera y verano, mientras que los fabricantes de equipo para la nieve y ropa de abrigo esperan un comportamiento anual opuesto al del fabricante de albercas.

**Variación cíclica (Toledo Muñoz, 1994):**

Con frecuencia las series de tiempo presentan secuencias alternas de puntos abajo y arriba de la línea de tendencia que duran más de un año, esta variación se mantiene después de que se han eliminado las variaciones o tendencias estacional e irregular. Un ejemplo de este tipo de variación son los ciclos comerciales cuyos períodos recurrentes dependen de la prosperidad, recesión, depresión y recuperación, las cuales no dependen de factores como el clima o las costumbres sociales.

### **Variación Irregular (Toledo Muñoz, 1994):**

Esta se debe a factores a corto plazo, imprevisibles y no recurrentes que afectan a la serie de tiempo. Como este componente explica la variabilidad aleatoria de la serie, es impredecible, es decir, no se puede esperar predecir su impacto sobre la serie de tiempo. Existen dos tipos de variación irregular:

- a) Las variaciones que son provocadas por acontecimientos especiales, fácilmente identificables, como las elecciones, inundaciones, huelgas, terremotos.
- b) Variaciones aleatorias o por casualidad, cuyas causas no se pueden señalar en forma exacta, pero que tienden a equilibrarse a la larga.

Para analizar la variación de los datos se utiliza el método de descomposición que suponen que los datos contienen patrones estacionales, cíclicos y de tendencia. Una función que representa esta relación puede ser la siguiente.

$$\text{Dato} = \text{patrón} + \text{error} = f(T_t, E_t, C_t, Er_t)$$

Donde:

$X_t$  = es el dato al periodo  $t$

$T_t$  es el componente de tendencia en el periodo  $t$ .

$E_t$  es el componente o índice de estacionalidad del periodo  $t$

$C_t$  es el componente cíclico del periodo  $t$ , y

$Er_t$  es el error del periodo  $t$

Las variaciones de sus aplicaciones de este método se dividen en ocho métodos de pronóstico que son los más utilizados y se explica a continuación.

#### 2.2.4.2 MÉTODOS DE PRONÓSTICOS DE SERIES DE TIEMPO

##### 1. Promedio Móvil Simple

(Soto, 2010):

Un promedio móvil simple o aritmético es calculado como la suma de un número predeterminado de valores por un cierto número de períodos de tiempo, dividido por el número de períodos de tiempo.

El resultado es el promedio en dicho período de tiempo.

Los promedios móviles simples emplean la misma ponderación para los valores. Es calculado usando la siguiente fórmula:

$$PM_t = \frac{X_t + X_{t-1} + X_{t-2} + \dots + X_{t-n+1}}{n}$$

Promedio Móvil Simple = SUMA (valores) / n, donde n es el número de períodos.

##### 2. Promedio Móvil Doble

(Ortiz Van Steenberghe, 2008):

El método consiste en calcular un conjunto de promedios móviles y en seguida se calcula un segundo conjunto como promedio móvil del primero.

Este método se utiliza para realizar pronósticos de series que tienen una tendencia lineal. Para su aplicación y cálculos es recomendable seguir el procedimiento que se indica en el siguiente procedimiento:

Se calcula el PMS, considerándose el conjunto de datos y los valores asignados para n:

$$M_t = \frac{X_t + X_{t-1} + X_{t-2} + \dots + X_{t-n+1}}{n}$$

Se determina el mejor pronóstico con antecedente en el menor error al cuadrado < (D-P).

Se calcula el promedio móvil doble, que resulta de promediar el primer móvil simple.

$$M'_t = \frac{M_t + M_{t-1} + M_{t-2} + \dots + M_{t-n+1}}{n}$$

Se calculan los valores correspondientes a:

Calcular la diferencia entre los dos promedios móviles.

$$a_t = 2M_t - M'_t$$

Calcular el factor adicional de ajuste:

$$b_t = 2 \frac{M_t - M'_t}{n-1}$$

Calcular el pronóstico para p periodos hacia el futuro.

$$y = a_t + b_t(x)$$

y = pronóstico deseado o buscado.

x = el periodo en el que se desea el pronóstico.

### 3. Suavizamiento Exponencial Simple

(Arbeleche Grela, 2005):

Esta técnica se basa en la atenuación de los valores de la serie de tiempo, obteniendo el promedio de estos de

manera exponencial; es decir, los datos se ponderan dando un mayor peso a las observaciones más recientes y uno menor a las más antiguas.

Al peso para ponderar la observación más reciente se le da el valor  $\alpha$ , la observación inmediata anterior se pondera con un peso de  $(1 - \alpha)$ , a la siguiente observación inmediata anterior se le da un peso de ponderación de  $(1 - \alpha)^2$  y así sucesivamente hasta completar el número de valores observados en la serie de tiempo a tomar en cuenta para realizar la atenuación, es decir, para calcular el promedio ponderado.

La estimación o pronóstico será el valor obtenido del cálculo del promedio. La expresión para realizar el cálculo de la atenuación exponencial es la siguiente:

$$P_{t+1} = \alpha X_t + \alpha(1-\alpha)X_{t-1} + \alpha(1-\alpha)^2 X_{t-2} + \dots + \alpha(1-\alpha)^{n-1} X_{t-(n-1)}$$

Otra expresión equivalente a esta es la siguiente:

$$P_{t+1} = \alpha X_t + (1 - \alpha)P_t$$

#### **4. Suavizamiento Exponencial Doble**

(Stair Jr., 2006):

Este método consiste en realizar dos suavizaciones exponenciales, a partir de las cuales se obtendrá el valor estimado, o pronóstico que buscamos realizar, mediante un cálculo realizado con una expresión sencilla. La primera se aplica a los valores observados en la serie de

tiempo y la segunda a la serie atenuada obtenida mediante la primera atenuación.

Debido a que los valores calculados al realizar las dos primeras atenuaciones no son los datos estimados a obtener, es decir, que constituirán las inferencias de los valores que se espera que tome la serie de tiempo en el futuro cercano, usaremos una notación distinta a la de la expresión final con la cual se calculan los valores que constituyen en realidad el pronóstico.

Las expresiones son las siguientes:

Cálculo de la suavización exponencial simple:

$$S_t = \alpha X_t + (1 - \alpha)S_{t-1}$$

Cálculo de la suavización exponencial doble:

$$S'_t = \alpha S_t + (1 - \alpha)S'_{t-1}$$

Cálculo de la diferencia de los dos ajustes exponenciales:

$$a_t = 2S_t - S'_t$$

Cálculo del factor adicional de ajuste:

$$b_t = \alpha \frac{(S_t - S'_t)}{1 - \alpha}$$

Cálculo del pronóstico para p periodos hacia el futuro:

$$P_{t+m} = a_t + b_t m$$

Donde m representa el número de periodos hacia el futuro del que se pretende hacer el pronóstico.

5. **Holt Winter's Aditivo** (Arbeleche Grela, 2005):

En este método la estacionalidad es aditiva con respecto de la tendencia, en lugar de ser multiplicativa.

Los diferentes componentes se combinan sumando donde "a" es la constante, "b" la tendencia y "c" el componente estacional.

$$\hat{y}_{t,t+k} = a_t + b_t \cdot k + c_{t+k-s}$$

Donde:

a= Representa una parte constante (un volumen de ventas de carácter fijo, en el caso de modelizar las ventas de una empresa).

b= representa la pendiente de la componente de tendencia (el ritmo estructural de crecimiento o decrecimiento del volumen de ventas).

c= representa el factor estacional en el periodo t (el incremento o descenso del volumen de ventas que viene explicado por el momento del tiempo en que se produce).

Las aproximaciones que este método plantea para los tres componentes son las siguientes:

$$a_t = \alpha_1 \frac{Y_t}{c_{t-s}} + (1 - \alpha_1)(a_{t-1} + b_{t-1})$$

$$b_t = \alpha_2 (a_t - a_{t-1}) + (1 - \alpha_2)b_{t-1}$$

$$c_t = \alpha_3 \frac{Y_t}{a_t} + (1 - \alpha_3)c_{t-s}$$

## 6. Holt Winter's Multiplicativo

(Stair Jr., 2006):

Se usa cuando la serie tiene una tendencia, al menos localmente, y un patrón estacional creciente.

$$\hat{y}_{t,t+k} = (a_t + b_t \cdot k)c_{t+k-s}$$

Las aproximaciones que este método plantea para los tres componentes son las siguientes:

$$a_t = \alpha_1 \frac{Y_t}{c_{t-s}} + (1 - \alpha_1)(a_{t-1} + b_{t-1})$$

$$b_t = \alpha_2 (a_t - a_{t-1}) + (1 - \alpha_2)b_{t-1}$$

$$c_t = \alpha_3 \frac{Y_t}{a_t} + (1 - \alpha_3)c_{t-s}$$

## 7. Estacional Aditivo

(Sapag Chain, 2007):

Se emplea cuando la serie de datos disponibles no muestra tendencia pero sí estacionalidad. Resulta una curva repetitiva que representa los promedios con estacionalidad.

## 8. Estacional Multiplicativo

(Sapag Chain, 2007):

Se usa cuando los datos no tienen una tendencia clara, existe estacionalidad y se observa crecimiento. Resulta una curva repetitiva creciente que representa el aumento de los promedios con estacionalidad.

## 2.2.5 REGRESIÓN LINEAL

En estadística la **regresión lineal** o **ajuste lineal** es un método matemático que modeliza la relación entre una variable dependiente  $Y$ , las variables independientes  $X_i$  y un término aleatorio  $\varepsilon$ . Este modelo puede ser expresado

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon$$

donde  $\beta_0$  es la intersección o término "constante", las  $\beta_i$  ( $i > 0$ ) son los parámetros respectivos a cada variable independiente, y  $p$  es el número de parámetros independientes a tener en cuenta en la regresión. La regresión lineal puede ser contrastada con la regresión no lineal.

### 2.2.5.1 EL MODELO DE REGRESIÓN LINEAL

El modelo lineal relaciona la variable dependiente  $Y$  con  $K$  variables explicativas  $X_k$  ( $k = 1, \dots, K$ ), o cualquier transformación de éstas, que generan un hiperplano de parámetros  $\beta_k$  desconocidos:

$$Y = \sum \beta_k X_k + \varepsilon$$

donde  $\varepsilon$  es la perturbación aleatoria que recoge todos aquellos factores de la realidad no controlables u observables y que por tanto se asocian con el azar, y es la que confiere al modelo su carácter estocástico. En el caso más sencillo, con una sola variable explicativa, el hiperplano es una recta:

$$Y = \beta_1 + \beta_2 X_2 + \varepsilon$$

El problema de la regresión consiste en elegir unos valores determinados para los parámetros desconocidos  $\beta_k$ , de modo que la ecuación quede completamente especificada. Para ello se necesita un conjunto de observaciones. En una observación cualquiera  $i$ -ésima ( $i=1, \dots, l$ ) se registra el comportamiento simultáneo de la variable dependiente y las variables explicativas (las perturbaciones aleatorias se suponen no observables).

$$Y_i = \sum \beta_k X_{ki} + \varepsilon_i$$

Los valores escogidos como estimadores de los parámetros,  $\hat{\beta}_k$ , son los coeficientes de regresión, sin que se pueda garantizar que coinciden con parámetros reales del proceso generador. Por tanto, en

$$Y_i = \sum \hat{\beta}_k X_{ki} + \hat{\varepsilon}_i$$

Los valores  $\hat{\varepsilon}_i$  son por su parte estimaciones de la perturbación aleatoria o errores.

#### **2.2.5.2 SUPUESTOS DEL MODELO DE REGRESIÓN LINEAL**

Para poder crear un modelo de regresión lineal, es necesario que se cumpla con los siguientes supuestos:

1. La relación entre las variables es lineal.
2. Los errores en la medición de las variables explicativas son independientes entre sí.
3. Los errores tienen varianza constante.

4. Los errores tienen una esperanza matemática igual a cero (los errores de una misma magnitud y distinto signo son equiprobables).
5. El error total es la suma de todos los errores.

### **2.2.5.3 TIPOS DE MODELOS DE REGRESIÓN LINEAL**

Existen diferentes tipos de regresión lineal que se clasifican de acuerdo a sus parámetros:

#### **A. Regresión lineal simple**

Sólo se maneja una variable independiente, por lo que sólo cuenta con dos parámetros. Si sabemos que existe una relación entre una variable denominada dependiente y otras denominadas independientes (como por ejemplo las existentes entre: la experiencia profesional de los trabajadores y sus respectivos sueldos, las estaturas y pesos de personas, la producción agraria y la cantidad de fertilizantes utilizados, etc.), puede darse el problema de que la dependiente asuma múltiples valores para una combinación de valores de las independientes.

"Y es una función de X"

$$Y = f(X)$$

Como Y depende de X,

Y es la variable dependiente, y

X es la variable independiente.

En el Modelo de Regresión es muy importante identificar cuál es la variable dependiente y cuál es la variable independiente. En el Modelo de Regresión Simple se establece que Y es una función de sólo una variable independiente, razón por la cual se le denomina también Regresión Divariada porque sólo hay dos variables, una dependiente y otra independiente y se representa así:

$$Y = f(X)$$

"Y está regresando por X"

La variable dependiente es la variable que se desea explicar, predecir. También se le llama "regresando" ó "variable de respuesta". La variable Independiente X se le denomina "variable explicativa" ó "regresor" y se le utiliza para explicar Y. Se calcula la ecuación de la recta que pasa por dos puntos dados. Sin embargo, en la regresión lineal por lo general se tiene más que dos puntos de datos, y raras veces están todos en una sola recta. El problema es que hallar la recta que ajusta los datos tan estrechamente que posible.

La Ecuación General es de la forma:

$$Y = mx + b$$

donde:

$$Pendiente = m = \frac{n \sum xy - (\sum x)(\sum y)}{n \sum x^2 - (\sum x)^2}$$

$$\text{Interseccion} = b = \frac{\sum y - m(\sum x)}{n}$$

$$\sum xy = \text{suma de productos} = x_1y_1 + x_2y_2 + x_3y_3 \dots x_ny_n$$

$$\sum y = \text{suma de valores de } y = y_1 + y_2 + y_3 \dots y_n$$

$$\sum x = \text{suma de valores de } x = x_1 + x_2 + x_3 \dots x_n$$

$$\sum x^2 = \text{suma de valores de } x^2 = x_1^2 + x_2^2 + x_3^2 \dots x_n^2$$

### **B. Regresión lineal múltiple**

La regresión lineal nos permite trabajar con una variable a nivel de intervalo o razón, así también se puede comprender la relación de dos o más variables y nos permitirá relacionar mediante ecuaciones, una variable en relación a otras variables llamándose Regresión múltiple.

Constantemente en la práctica de la investigación estadística, se encuentran variables que de alguna manera están relacionados entre si, por lo que es posible que una de las variables puedan relacionarse matemáticamente en función de otra u otras variables. Maneja varias variables independientes. Cuenta con varios parámetros. Se expresan de la forma:

$$Y = a_0 + a_1x_1 + a_2x_2 + a_3x_3 + \dots + a_ix_i$$

### **C. Rectas de regresión**

Las rectas de regresión son las rectas que mejor se ajustan a la nube de puntos (o también llamado diagrama

de dispersión) generada por una distribución binomial. Matemáticamente, son posibles dos rectas de máximo ajuste:

- La recta de regresión de Y sobre X:

$$y = \bar{y} + \frac{\sigma_{xy}}{\sigma_x^2} (x - \bar{x})$$

- La recta de regresión de X sobre Y:

$$x = \bar{x} + \frac{\sigma_{xy}}{\sigma_y^2} (y - \bar{y})$$

La correlación ("r") de las rectas determinará la calidad del ajuste. Si r es cercano o igual a 1, el ajuste será bueno y las predicciones realizadas a partir del modelo obtenido serán muy fiables (el modelo obtenido resulta verdaderamente representativo); si r es cercano o igual a 0, se tratará de un ajuste malo en el que las predicciones que se realicen a partir del modelo obtenido no serán fiables (el modelo obtenido no resulta representativo de la realidad). Ambas rectas de regresión se intersecan en un punto llamado centro de gravedad de la distribución.

## **CAPITULO III**

### **METODOLOGÍA DE LA INVESTIGACIÓN**

#### **3.1 TIPO DE INVESTIGACIÓN**

La presente investigación es aplicada, descriptiva, explicativa y experimental.

Es aplicada, porque se construye un modelo de RNA recurrente para las variables de Marketing y Ventas de la industria de planificación.

Es descriptiva, puesto que se hace una descripción del comportamiento de las variables de estudio.

Es explicativa puesto que se explica el comportamiento de las variables de marketing y ventas a través los factores que influyen como las estaciones y el tiempo.

Finalmente, es experimental porque pues habrá manipulación de la variable independiente que son los modelos de predicción para observar la precisión en sus pronósticos de las variables de marketing y ventas.

### 3.2 DISEÑO DE LA INVESTIGACIÓN

El diseño de investigación es pre-experimental, pues la muestra de los datos a analizar no es aleatoria y no se maneja grupo de control.

A continuación presentaremos de manera secuencial el conjunto de pasos que se realizará para lograr el objetivo de la investigación.

- a. Análisis y Selección de las variables críticas de éxito de Marketing y Ventas.
- b. Diseño del Modelo de Red Neuronal Recurrente asociado al área de Marketing y Ventas
- c. Validación del Modelo Red Neuronal Recurrente asociado al área de Marketing y Ventas
- d. Predicción del comportamiento de las variables de marketing y ventas utilizando las técnicas estadísticas.
- e. Comparar la precisión del pronóstico del modelo de red neuronal recurrente con los modelos estadísticos.

### 3.3 ESQUEMA DEL DISEÑO DE INVESTIGACIÓN

En la figura 12 se presenta el esquema de investigación que tiene tres fases.

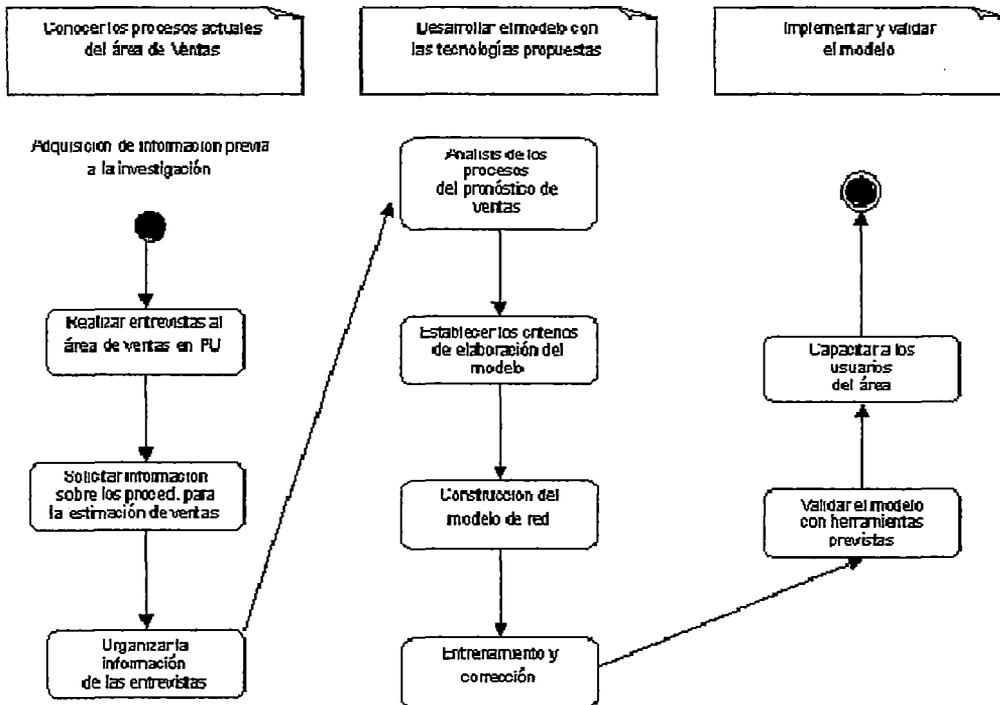


Figura 12 – Esquema de la Investigación

### **3.4 POBLACIÓN Y MUESTRA**

La unidad de análisis son las *ventas mensuales* de los productos de pastelería de la empresa PU. Entonces, la población está conformada por las ventas mensuales de una línea de producto comprendido desde diciembre del 2005 a diciembre del 2009. De acuerdo a Hernández Sampieri (2003) la muestra para este tipo de estudio es una muestra intencional. En este caso se considera los últimos cuatro años; puesto que la data histórica de años anteriores no es fidedigno debido a los problemas de registro de datos en los sistemas operacionales.

Tamaño de la muestra:  $n = 49$  meses

### **3.5 VARIABLES E INDICADORES**

#### **3.5.1 VARIABLE INDEPENDIENTE: MODELOS DE PRONÓSTICO**

##### **Modelo de RNA Recurrente**

Es un tipo de red neuronal artificial que se orienta a realizar pronósticos cuya característica es la retroalimentación; es decir que la neurona se retroalimenta así misma y cuya retroalimentación puede ser local o global.

##### **Modelo estadístico de regresión lineal**

Es un modelo basado en una ecuación lineal el cual consiste en determinar la pendiente y el coeficiente de la ecuación a través de la data histórica.

##### **Modelo de series de tiempo:**

Es un modelo que trabaja en función a los periodos anteriores para estimar un periodo futuro de la variable a pronosticar. En el presente estudio se ha trabajado con ocho modelos de series de tiempo.

### **3.5.2 VARIABLE DEPENDIENTE:** Precisión en la Predicción del Variables de Marketing y Ventas

Cuando se realiza pronóstico de una variable, siempre se tiene un margen de error o un grado de confiabilidad. Naturalmente lo que se espera es tener el mínimo error posible o el más alto grado de confiabilidad.

El modelo de red neuronal o las técnicas estadísticas, manejan el error que existe en la estimación o el nivel de confiabilidad del modelo, motivo por el cual se utilizará estos indicadores para observar la efectividad del modelo.

#### **Indicador de comparación:**

Para definir el método que tiene mayor precisión en el pronóstico se utiliza el indicador del Error cuadrático medio (NMSE) puesto que los tres modelos de estudio contemplan este indicador de desempeño.

## **3.6 TECNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS**

### **3.6.1 TECNICAS DE INVESTIGACIÓN**

Se utilizó dos técnicas para la recopilación de datos: la técnica ETL (Extracción, Transformación y Carga de Datos) y análisis documental.

Técnica ETL: esta técnica consiste en tres partes que describiremos a continuación.

- Extracción: Puesto que los datos se encuentran en una base de datos, se identificó en que tablas se encontraban los datos para la investigación.
- Transformación: Una vez identificado las tablas que contenían los datos, se elaboraron consultas SQL para extraer la data. Esta data estaba sumariada mensualmente.

- Carga de Datos: finalmente, guardar los datos transformados, se diseñó un pequeño repositorio de datos en SQL Server 2000; es decir, se construyó un datamart.

Análisis de documentos: para obtener la información se analizó los reportes de ventas mensuales.

### 3.6.2 INSTRUMENTOS DE RECOLECCIÓN DE DATOS

Para recopilar los datos se utilizó una ficha de pronóstico para los diferentes modelos de pronóstico que se presenta a continuación.

Ficha de Pronostico con Series de Tiempo:

#### FICHA DEL MODELO: SERIES DE TIEMPO

<b>MODELO DE PRONÓSTICO</b>	Disenado Por: _____
<b>TECNICA DE PRONÓSTICO</b>	
<b>PERIODO DE ANÁLISIS:</b>	
<b>PUNTOS DE CONTROL:</b>	
<b>OBJETIVO(S):</b>	
Padrino del Modelo - Sponsor _____	Gerente Usuario (Area de Interes) _____
Proveedor del Servicio (Responsable del Pronóstico) _____	Responsable de Data Histórica (Fuente) _____

#### FICHA DE RESULTADOS: SERIES DE TIEMPO

<b>OBJETIVO</b>						
<b>INDICADOR</b>	<b>HORIZONTE DE TIEMPO</b>			<b>MEJOR METODO:</b>		
	<b>Comienzo</b>	<b>Fin</b>	<b>Nro de Per.</b>	<b>RMSE</b>	<b>MAD</b>	<b>MAPE</b>
Margen de Utilidad			0			
<b>ANALISIS</b>	Tendencia					
	Ciclos					
	Predicción					
<b>EXTRAPOBLACIÓN (Forecast)</b>	<b>Inrvalo de Confianza (95%)</b>			<b>TOMA DE DECISIONES</b>		
	<b>Inferior</b>	<b>Forecast</b>	<b>Superior</b>	<b>Decisión</b>	<b>Real</b>	<b>Error</b>
Enero						
Febrero						
Marzo						
Abril						

## FICHA DE RESULTADOS: MODELO DE RNA RECURRENTE

<b>OBJETIVO</b>					
<b>INDICADOR</b>	<b>HORIZONTE DE TIEMPO</b>			<b>COSTO DE APRENDIZAJE Y ERROR:</b>	
	Comienzo	Fin	Nro de Per.	FACTOR	COSTO
			0		EG
<b>ANALISIS</b>	Tendencia				
	Ciclos				
	Predicción				
<b>PERIODOS HISTÓRICOS</b>	<b>INTERPOLACIÓN</b>			<b>PRONÓSTICO</b>	
	Deseado	Salida	Error	Periodos	Pronóstico
Enero				Mayo	
Febrero				Junio	
Marzo				Julio	
Abril				Agosto	
<b>RECOMENDACIONES</b>					
<b>GRAFICA DEL FORECASTING</b>					
Estado de Escenario <input type="radio"/> En Ejecución <input type="radio"/> En Estudio <input checked="" type="radio"/> Archivado					
				Revisión: 1 Fecha:	

## **CAPITULO IV**

### **ANALISIS E INTERPRETACIÓN DE LOS RESULTADOS DEL PRONÓSTICO DE LAS VARIABLES DE MARKETING Y VENTAS**

#### **4.1 DESCRIPCION DE LAS VARIABLES DE PRONÓSTICO**

Para realizar el pronóstico con los diferentes modelos, se ha considerado ocho variables de marketing y ventas que se describe a continuación.

##### **4.1.1 DESCRIPCION DE LAS VARIABLES:**

**Variables independientes:** se ha considerado ocho variables independientes que son:

- **Año:** para esta variable se ha considerado desde diciembre del 2005 hasta diciembre del 2009
- **Estacionalidad:** Se ha trabajado con las cuatro estaciones del año
- **Mes:** La unidad de análisis está en función a los meses del año

- **Volumen de Devolución:** se considera devolución a los productos que son devueltos o que no se han vendido. El volumen de devolución es la suma de un mes de las devoluciones que se tiene por cada día.
- **Tendencia de devoluciones:** es el ratio en función a la variación de la devolución de un periodo anterior para ver el comportamiento de la variable. La fórmula que se utiliza para esta variable es la misma que se uso para calcular la tendencia de ventas.
- **Cuota de devolución:** Es el porcentaje del volumen de devolución en función al volumen de venta.

$$\text{Cuota de Devolución} = \frac{\text{Volumen de Devolución}}{\text{Volumen de Venta}} (100)$$

- **Tendencia de ventas:** es el ratio en función a la variación de la venta de un periodo anterior para ver el comportamiento de la variable y la formula que se utilizó es:

$$T_{i+1} = \frac{P_{i+1} - P_i}{P_i}$$

Donde:

$T_{i+1}$  : es la tendencia del periodo siguiente

$P_{i+1}$  : es el dato del periodo siguiente

$P_i$  : es el dato del periodo base

**Variable dependiente:** de acuerdo al interés de la información que necesita la gerencia se ha considerado la siguiente variable dependiente:

- **Volumen de Venta:** Se ha considerado el volumen de venta mensual de los productos que corresponden a la categoría de pastelería.

#### **4.1.2 DESCRIPCION DE LA DATA HISTÓRICA DE LAS VARIABLES DE ESTUDIO.**

En el cuadro 4.1 se presenta la data histórica de las variables con la cual se ha trabajado. En esta data histórica solo se ha considerado los productos correspondientes a la categoría de pastelería.

Cuadro 4.1 Data histórica de las variables de pronóstico

Año	Est	Mes	Volumen de Venta	Tendencia de Venta	Volumen de Devolución	Tendencia de Devolución	Cuota de Devolución (%)
2005	3	12	333,714.40		6,517.01		1.95%
2006	1.5	1	165,484.55	-0.504	7,624.59	0.170	4.61%
2006	1.6	2	160,253.27	-0.032	6,503.49	-0.147	4.06%
2006	2	3	213,592.76	0.333	6,517.01	0.002	3.05%
2006	2	4	214,925.12	0.006	7,624.59	0.170	3.55%
2006	3	5	304,029.92	0.415	6,503.49	-0.147	2.14%
2006	3	6	299,866.65	-0.014	6,023.96	-0.074	2.01%
2006	3	7	303,518.70	0.012	4,152.80	-0.311	1.37%
2006	3	8	294,344.94	-0.030	8,351.51	1.011	2.84%
2006	3	9	295,527.61	0.004	5,965.68	-0.286	2.02%
2006	3	10	273,940.66	-0.073	6,445.24	0.080	2.35%
2006	3	11	283,293.38	0.034	8,125.22	0.261	2.87%
2006	3	12	306,803.74	0.083	8,865.64	0.091	2.89%
2007	2	1	189,325.20	-0.383	9,193.48	0.037	4.86%
2007	2	2	176,925.89	-0.065	10,284.50	0.119	5.81%
2007	2.5	3	250,103.55	0.414	5,986.73	-0.418	2.39%
2007	3	4	273,357.33	0.093	5,185.93	-0.134	1.90%
2007	4	5	389,880.72	0.426	4,633.32	-0.107	1.19%
2007	4	6	381,478.01	-0.022	4,275.76	-0.077	1.12%
2007	4	7	382,559.88	0.003	5,103.40	0.194	1.33%
2007	4	8	416,348.95	0.088	4,217.32	-0.174	1.01%
2007	4	9	432,642.93	0.039	4,624.67	0.097	1.07%
2007	4.5	10	457,346.28	0.057	6,360.57	0.375	1.39%
2007	4.5	11	436,819.84	-0.045	6,370.76	0.002	1.46%
2007	3.5	12	367,133.59	-0.160	7,520.63	0.180	2.05%
2008	2.5	1	251,656.37	-0.315	6,838.54	-0.091	2.72%
2008	2.5	2	263,960.65	0.049	9,096.30	0.330	3.45%
2008	2.5	3	275,952.45	0.045	7,970.63	-0.124	2.89%
2008	3	4	331,391.39	0.201	7,477.08	-0.062	2.26%
2008	4.5	5	443,774.07	0.339	5,822.58	-0.221	1.31%
2008	4.5	6	456,834.62	0.029	3,503.02	-0.398	0.77%
2008	4.5	7	454,958.94	-0.004	4,762.47	0.360	1.05%
2008	4.5	8	480,283.38	0.056	4,613.69	-0.031	0.96%
2008	5	9	517,181.85	0.077	7,445.85	0.614	1.44%
2008	5	10	557,001.83	0.077	7,394.47	-0.007	1.33%
2008	5.5	11	429,632.16	-0.229	7,863.81	0.063	1.83%
2008	4	12	371,697.72	-0.135	8,108.96	0.031	2.18%
2009	2.5	1	255,861.37	-0.312	8,790.41	0.084	3.44%
2009	2.5	2	257,652.17	0.007	9,585.51	0.090	3.72%
2009	3	3	316,271.26	0.228	11,271.32	0.176	3.56%
2009	3.5	4	343,779.05	0.087	12,730.46	0.129	3.70%
2009	1.5	5	166,996.17	-0.514	2,533.73	-0.801	1.52%
2009	3	6	327,497.57	0.961	6,165.69	1.433	1.88%
2009	4	7	417,233.87	0.274	6,391.06	0.037	1.53%
2009	4.5	8	463,074.71	0.110	5,457.00	-0.146	1.18%
2009	4.3	9	435,538.36	-0.059	6,355.53	0.165	1.46%
2009	4.3	10	436,300.32	0.002	7,353.30	0.157	1.69%
2009	4	11	418,586.18	-0.041	6,386.79	-0.131	1.53%
2009	3.5	12	366,384.08	-0.125	7,252.71	0.136	1.98%

## 4.2 PRONÓSTICO CON SERIES DE TIEMPO

En el mundo empresarial los modelos más utilizados para analizar el comportamiento futuro de las variables de marketing y ventas son las series de tiempo.

En el cuadro 4.2 se presenta los resultados del pronóstico de las ventas mensuales utilizando ocho métodos de series de tiempo.

Cuadro 4.2: Cuadro comparativo de las técnicas de series de tiempo

Métodos	Ranking	RMSE	MAD	MAPE	Durbin-Watson	Theil's U	Alpha	Beta	Gamma
Double Exponential Smoothing	1	64303	45218	15.161	1.824	1.001	0.999	0.001	
Double Moving Average	6	87978	65694	21.932	1.796	1.465			
Holt-Winters' Additive	5	85736	68104	22.115	1.591	1.256	0.729	0.001	0.999
Holt-Winters' Multiplicative	8	91383	76535	23.775	1.568	1.26	0.72	0.001	0.987
Seasonal Additive	4	85696	68087	22.105	1.591	1.255	0.729		0.999
Seasonal Multiplicative	7	91318	76492	23.758	1.568	1.259	0.720		0.987
Single Exponential Smoothing	3	68072	47757	16.956	1.711	1	0.999		
Single Moving Average	2	68067	47748	16.952	1.713	1			

Fuente propia

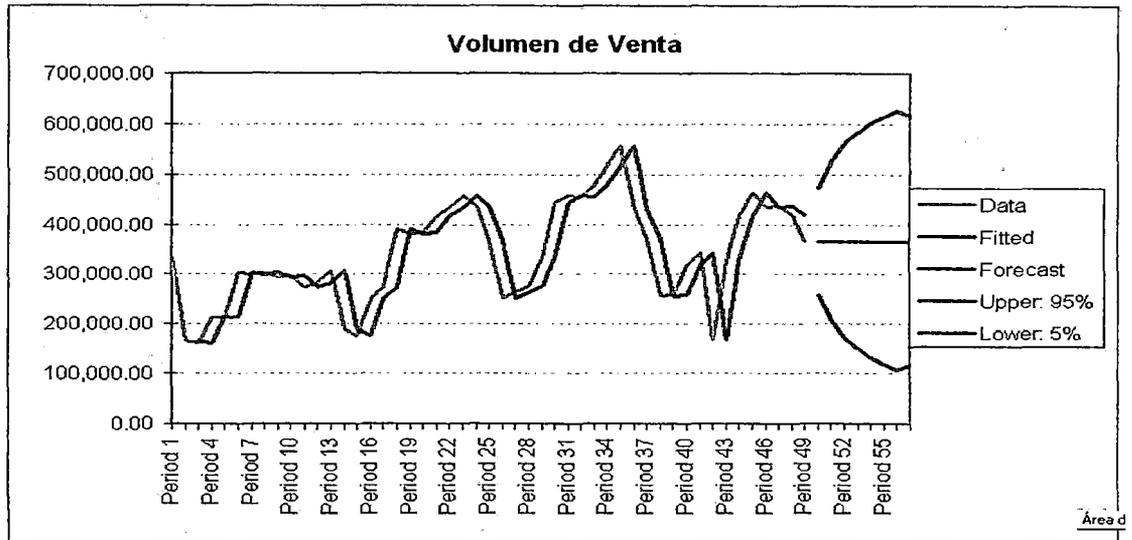
En el cuadro 4.2 se observa que el método de suavizamiento exponencial doble (Double Exponential Smoothing) tiene la menor desviación media (MAD) y el menor error cuadrático medio (RMSE) frente a los demás métodos, del cual se deduce que este método es el que tiene menos error en el pronóstico de ventas.

En el cuadro 4.3 se presenta el pronóstico de ventas para los cuatro siguientes meses del 2010 con un intervalo de confianza del 95% a nivel superior y un 5% a nivel inferior. Además, se presenta también el residuo para luego comparar con los otros modelos de pronóstico.

Cuadro 4.3: Pronóstico de ventas de cuatro meses y su intervalo de confianza

Date	Historical Data	Lower: 5%	Fit & Forecast	Upper: 95%	Residuals
Period 1	333,714.40				333,714.40
Period 2	165,484.55				165,484.55
Period 3	160,253.27		165,484.84		-5,231.57
Period 4	213,592.76		160,085.22		53,507.54
Period 5	214,925.12		213,419.38		1,505.74
Period 6	304,029.92		214,805.28		89,224.64
Period 7	299,866.65		303,911.44		-4,044.79
Period 8	303,518.70		299,837.46		3,681.23
Period 9	294,344.94		303,485.45		-9,140.52
Period 10	295,527.61		294,315.39		1,212.22
Period 11	273,940.66		295,488.92		-21,548.26
Period 12	283,293.38		273,903.22		9,390.16
Period 13	306,803.74		283,234.36		23,569.38
Period 14	189,325.20		306,754.07		-117,428.87
Period 15	176,925.89		189,299.32		-12,373.43
Period 16	250,103.55		176,782.53		73,321.02
Period 17	273,357.33		249,947.67		23,409.65
Period 18	389,880.72		273,274.78		116,605.93
Period 19	381,478.01		389,821.40		-8,343.39
Period 20	382,559.88		381,535.40		1,024.48
Period 21	416,348.95		382,608.91		33,740.04
Period 22	432,642.93		416,398.95		16,243.98
Period 23	457,346.28		432,726.67		24,619.61
Period 24	436,819.84		457,446.23		-20,626.39
Period 25	367,133.59		436,944.47		-69,810.88
Period 26	251,656.37		367,237.69		-115,581.32
Period 27	263,960.65		251,690.81		12,269.84
Period 28	275,952.45		263,879.41		12,073.04
Period 29	331,391.39		275,883.46		55,507.93
Period 30	443,774.07		331,334.39		112,439.68
Period 31	456,834.62		443,772.43		13,062.19
Period 32	454,958.94		456,945.47		-1,986.53
Period 33	480,283.38		455,082.87		25,200.51
Period 34	517,181.85		480,405.28		36,776.58
Period 35	557,001.83		517,328.90		39,672.93
Period 36	429,632.16		557,185.62		-127,553.46
Period 37	371,697.72		429,855.87		-58,158.14
Period 38	255,861.37		371,793.89		-115,932.52
Period 39	257,652.17		255,899.53		1,752.64
Period 40	316,271.26		257,574.31		58,696.95
Period 41	343,779.05		316,195.06		27,583.99
Period 42	166,996.17		343,761.54		-176,765.37
Period 43	327,497.57		167,006.56		160,491.01
Period 44	417,233.87		327,330.80		89,903.07
Period 45	463,074.71		417,227.55		45,847.16
Period 46	435,538.36		463,158.28		-27,619.92
Period 47	436,300.32		435,667.85		632.46
Period 48	418,586.18		436,402.17		-17,816.00
Period 49	366,384.08		418,688.69		-52,304.61
Period 50		259,554.21	366,468.86	473,383.52	
Period 51		208,525.24	366,501.30	524,477.36	
Period 52		172,276.12	366,533.74	560,791.35	
Period 53		149,361.54	366,566.17	583,770.81	
Period 54		131,006.14	366,598.61	602,191.08	
Period 55		117,602.55	366,631.05	615,659.55	

Figura 4.1: Gráfica comparativa de la data real versus data ajustada con su pronóstico



Fuente: datos de la variable de estudio

En la figura 4.1 se observa que la data ajustada es similar a la data real; sin embargo el intervalo de confianza para el pronóstico de los cuatro siguientes periodos es muy amplio.

### 4.3 PRONÓSTICO CON REGRESIÓN LINEAL

El siguiente modelo estadístico que se utilizó para el pronóstico de las ventas futuras ha sido el de multiregresión lineal.

En este modelo se ha considerado siete variables independientes y una dependiente tal como se muestra en el cuadro 4.4.

Cuadro 4.4: Análisis del modelo de regresión lineal con siete variables independientes

**Coefficientes<sup>a</sup>**

	Coefficients no estandarizados		Coefficients estandarizados	t	Sig.	Intervalo de confianza para B al 95%	
	B	Error tip.	Beta			Límite inferior	Límite superior
1 (Constante)	-8.E+06	7582269		-1.087	.284	-23551833.0	7073571
AÑO	4151.149	3776.350	.049	1.099	.278	-3475.344	11777.643
ESTACION	78532.43	7187.159	.790	10.927	.000	64017.666	93047.192
MES	-115.173	1600.945	-.004	-.072	.943	-3348.347	3118.001
TENDENCIA VENTA	14359.12	17196.524	.036	.835	.409	-20369.967	49088.202
DEVOLUCIÓN	4.076	4.373	.081	.932	.357	-4.755	12.908
TENDENCIA DEVOLUCIÓN	8530.278	12185.171	.029	.700	.488	-16078.174	33138.729
DEVOLUCIÓN (%)	-20576.9	11302.862	-.236	-1.821	.076	-43403.490	2249.695
2 (Constante)	-9.E+06	6448011		-1.321	.194	-21529488.2	4495739
AÑO	4289.169	3213.951	.051	1.335	.189	-2196.846	10775.184
ESTACION	78501.12	7088.497	.790	11.074	.000	64195.952	92806.282
TENDENCIA VENTA	14834.62	15686.407	.037	.946	.350	-16821.832	46491.071
DEVOLUCIÓN	3.937	3.874	.078	1.016	.315	-3.881	11.755
TENDENCIA DEVOLUCIÓN	8329.095	11718.630	.028	.711	.481	-15320.058	31978.249
DEVOLUCIÓN (%)	-20150.0	9505.354	-.231	-2.120	.040	-39332.592	-967.428
3 (Constante)	-8.E+06	6392706		-1.278	.208	-21064877.7	4719363
AÑO	4114.605	3186.061	.049	1.291	.203	-2310.699	10539.909
ESTACION	79218.14	6975.856	.797	11.356	.000	65149.987	93286.295
TENDENCIA VENTA	18658.36	14649.997	.047	1.274	.210	-10886.174	48202.895
DEVOLUCIÓN	4.448	3.785	.088	1.175	.246	-3.186	12.081
DEVOLUCIÓN (%)	-19806.5	9438.282	-.227	-2.099	.042	-38840.628	-772.409
4 (Constante)	-1.E+07	6095615		-1.728	.091	-22816192.4	1753619
AÑO	5284.440	3039.582	.063	1.739	.089	-841.435	11410.315
ESTACION	84649.94	5246.851	.852	16.133	.000	74075.604	95224.271
TENDENCIA VENTA	23698.68	14068.408	.059	1.685	.099	-4654.335	52051.693
DEVOLUCIÓN (%)	-10050.8	4508.190	-.115	-2.229	.031	-19136.483	-965.163

a. Variable dependiente: VENTA

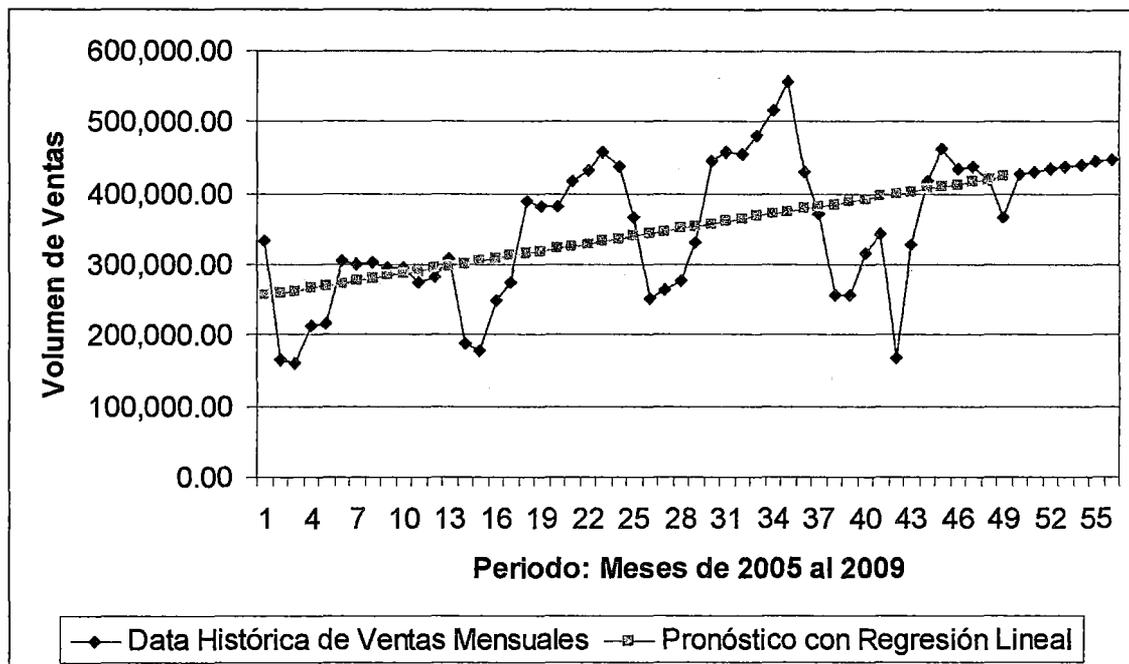
En el cuadro 4.4 se observa que se han introducido siete variables independientes para ver su efecto en la variable dependiente. En la columna 4 se observa que solo han sido eliminadas tres variables y solo quedaron cuatro variables que tienen una influencia significativa y son: Año, Estación, Tendencia de Venta y Porcentaje de Devolución.

Considerando un alfa de 0.05 (que es un nivel de significancia generalmente aceptable), de acuerdo a los resultados que se presenta en el cuadro 4.4 en la fila cuatro, solo quedarían dos variables para utilizar este modelo: estación y el porcentaje de devolución pues su nivel de significancia es de 0.00 y 0.31 respectivamente.

Uno de los parámetros que se considera en este modelo es la constante que le acompaña en esta ecuación, y en el cuadro 4.4 se observa que el nivel de significancia para utilizar este parámetro es de 0.091 que es mayor a 0.05. Entonces, se deduce que esta constante no es confiable utilizar en el modelo, ya que no es significativa y presenta casi un 10% de margen de error.

Por lo tanto, el modelo de multiregresión lineal no logra ajustarse con un mínimo margen (5%) de error. Entonces, no es posible utilizar este modelo estadístico para hacer el pronóstico del comportamiento de la variable de estudio.

Figura 4.2: pronóstico del volumen de ventas mensual con el modelo de regresión lineal.



En la figura 4.2 se puede observar que el modelo de regresión lineal hace un pronóstico lineal con una tendencia positiva.

#### 4.4 PRONOSTICO CON RNA RECURRENTES

##### 4.4.1 ARQUITECTURA DE ELMAN DE LA RNA RECURRENTE PARA PRONÓSTICO

La arquitectura que se ajusta al comportamiento de las variables de marketing y ventas es la red de Elman (1990) que se presenta en la figura 4.3. Esta arquitectura contiene conexiones recurrentes de las neuronas ocultas a la capa de unidades contextuales consistente en retardos unitarios. Estas unidades contextuales almacenan las salidas de las neuronas ocultas, lo que les permite desarrollar las tareas de aprendizaje a través del tiempo. Las neuronas ocultas también alimentan a las neuronas de salida. Debido a la naturaleza de la retroalimentación alrededor de las

neuronas ocultas, estas neuronas pueden continuar reciclando información a través de la red durante muchos pasos en el tiempo y así obtener representaciones abstractas del tiempo.

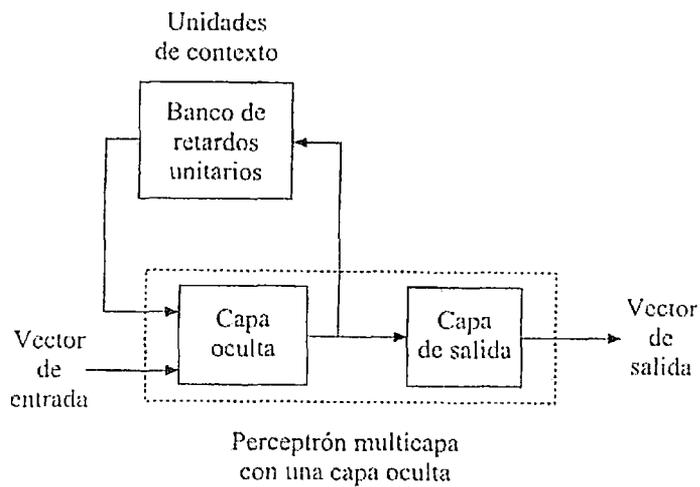


Figura 4.3: Arquitectura de una RNA recurrente de Elman

Donde:

Capa de entrada:

Vector de entrada: se tiene 8 variables mencionadas en la sección 4.1

Vector de salida: 25 salidas

En la capa de entrada se define el Banco de Retardos Unitarios

Capa Oculta

Vector de entrada: 3

Vector de salida: 3

Función de Transferencia: Tangente Hiperbólico

Capa de salida:

Vector de entrada: 3

Vector de salida: 1

Función de Transferencia: Bias

Pesos Iniciales: Aleatorios

Para obtener la red neuronal artificial recurrente óptima que se ajusta al comportamiento de las variables de marketing y ventas, se trabajó con el software de investigación de Neuro Solution en el cual se ha construido la arquitectura de Elman. En la figura 4.4 se presenta la Red Neuronal Recurrente configurada en Neuro Solution.

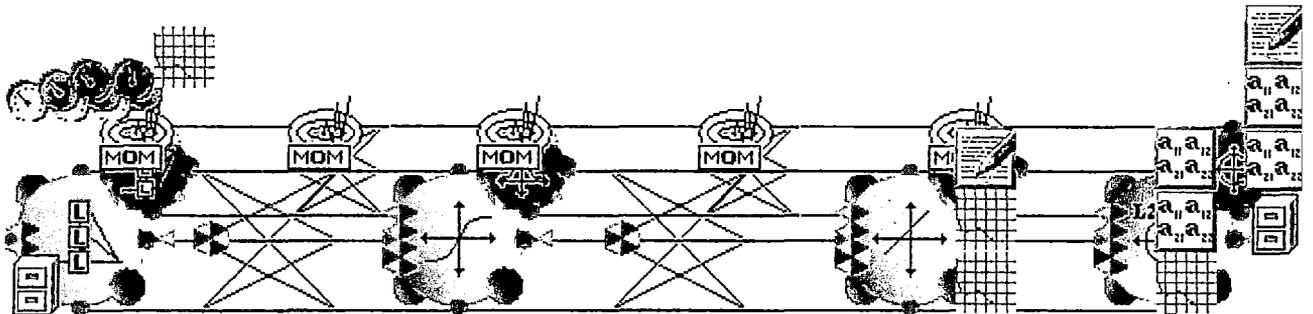


Figura 4.4: RNA Recurrente del Elman configurada en Neuro Solution

Para entender la funcionalidad de cada componente de la RNA

Recurrente que se presenta en la figura 4.4 puede ver el anexo.

El entrenamiento se ha trabajado en dos estados: estático y dinámico

El estado estático consiste en entrenar a la RNA con parámetros de aprendizaje de manera estática lo cual dificulta el aprendizaje de la Red.

El estado dinámico consiste en utilizar algoritmos genéticos para obtener los parámetros óptimos de aprendizaje.

#### 4.4.1.1 ENTRENAMIENTO ESTÁTICO

Para entrenar a la red es necesario inicializar los pesos de toda la red; y para este caso la inicialización de los pesos es aleatoria.

El factor de aprendizaje (alfa) será de 0.7 que es el más recomendado.

El entrenamiento es de 200 épocas.

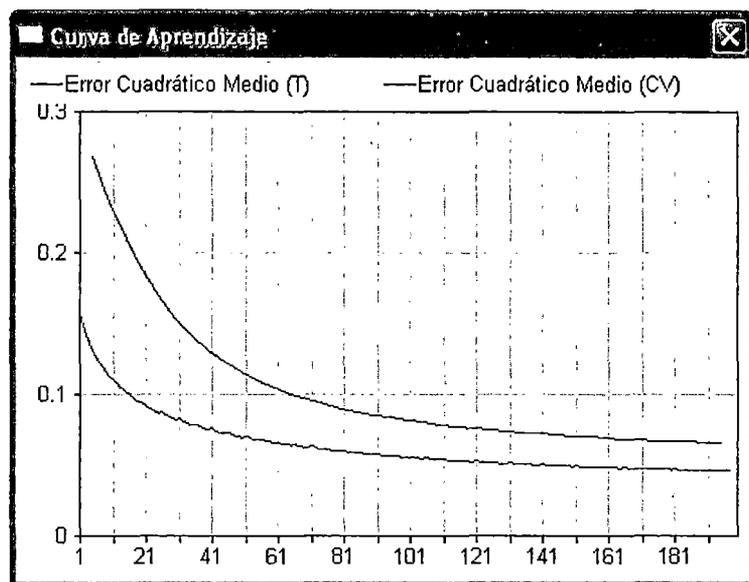


Figura 4.5: Curva de aprendizaje de la RNA Recurrente

En la figura 4.5 se observa como el error cuadrático medio empieza a decrecer a medida que se va entrenando la red. En particular en la época 198 el error cuadrático medio llego a reducirse a 0.046100020863 el cual indica que la RNA está logrando un buen aprendizaje.

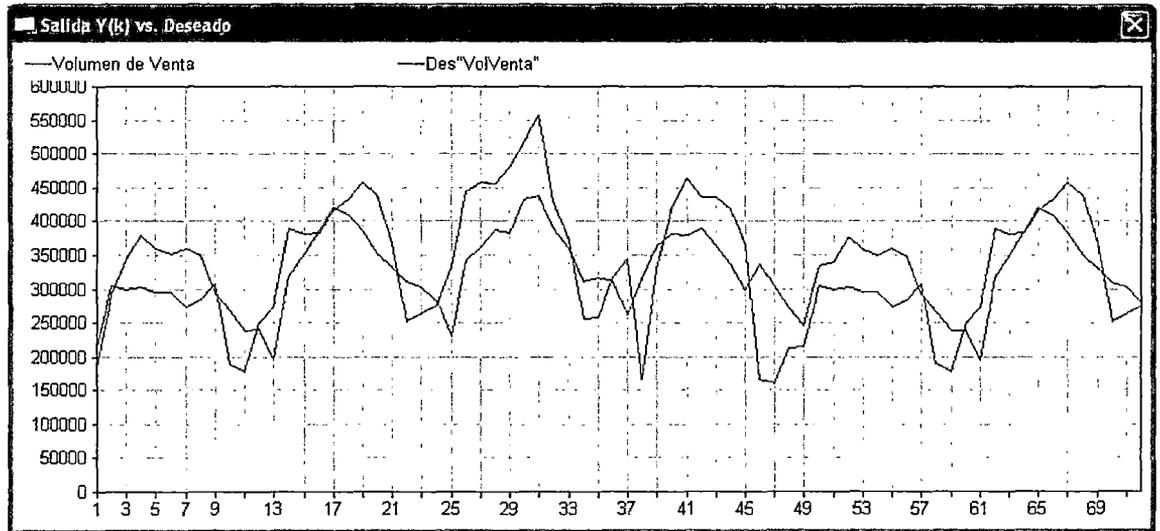


Figura 4.6: Comparación del ajuste de la RNA Recurrente con la data real

En la figura anterior se observa que existe mucha diferencia entre la data deseada (data real) y la salida de la RNA Recurrente. La línea azul representa la data histórica de ventas y la roja la data pronosticada por la red neuronal.

En efecto, de acuerdo a los resultados presentados se deduce que la red no presenta el grado de validez para realizar los pronósticos de las ventas.

#### 4.4.1.2 ENTRENAMIENTO DINÁMICO: OPTIMIZACIÓN CON ALGORITMOS GENÉTICOS

Configuración de datos iniciales

Pesos Iniciales: los pesos iniciales son aleatorios

Puesto que se utilizará el entrenamiento dinámico utilizando algoritmos genéticos para obtener el óptimo ratio de aprendizaje, es necesario definir algunos parámetros de optimización.

Las configuraciones iniciales son rangos en los cuales oscila el ratio de aprendizaje.

Parámetros de optimización de Algoritmos Genéticos:

**Longitud de Paso (LP): 0.01**

Frontera Inferior de LP: 0.01

Frontera Superior de LP: 1.00

**Ratio de Aprendizaje inicial: 0.07**

Frontera Inferior de RA: 0.00

Frontera Superior de RA: 0.2

**Tipo de Mutación: Uniforme**

Luego de configurar los parámetros de optimización, se ha simulado el modelo durante una hora. En la simulación se ha logrado simular con 96 generaciones. Cada generación trabajo con 40 cromosomas y 1000 épocas. En la figura 4.7 se presenta los detalles de la optimización con algoritmos genéticos.

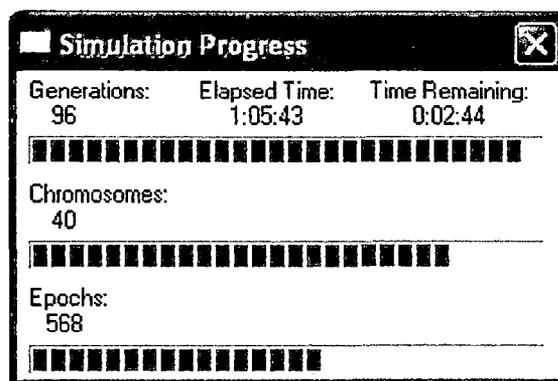


Figura 4.7. Monitoreo de la optimización de la red con algoritmos genéticos.

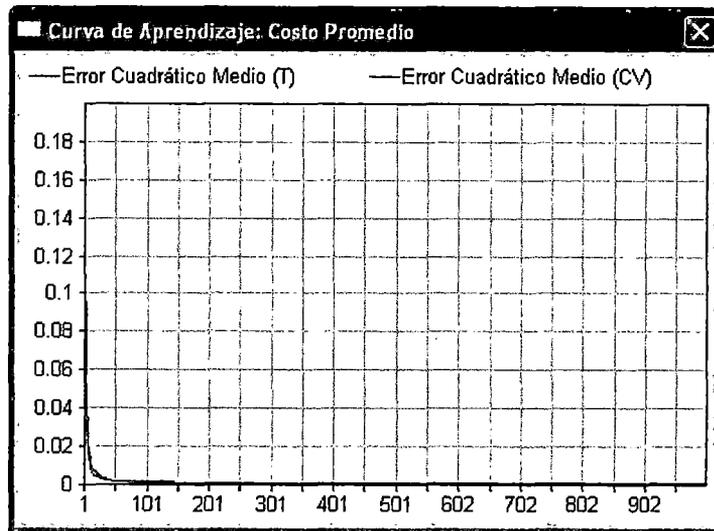


Figura 4.8: Curva de aprendizaje con 1000 épocas

En la figura 4.8 se observa que el error cuadrático medio llega al mínimo en la época de entrenamiento nro 12 y a partir de ahí la curva de aprendizaje tiene una mínima variación con tendencia a cero.

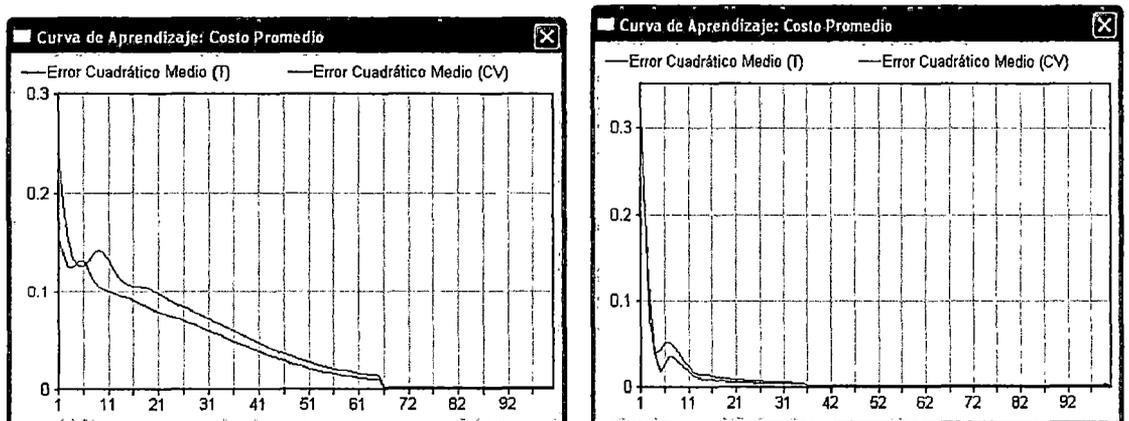


Figura 4.9. Curva de aprendizaje con 100 épocas

En la figura 4.9 se observa que el error cuadrático medio llega un nivel mínimo en la época 65 y 35 respectivamente. El gráfico de la figura 4.9 del lado derecho ha sido después de una generación del cual se

deduce que a medida que logra entrenar, el aprendizaje es más rápido.

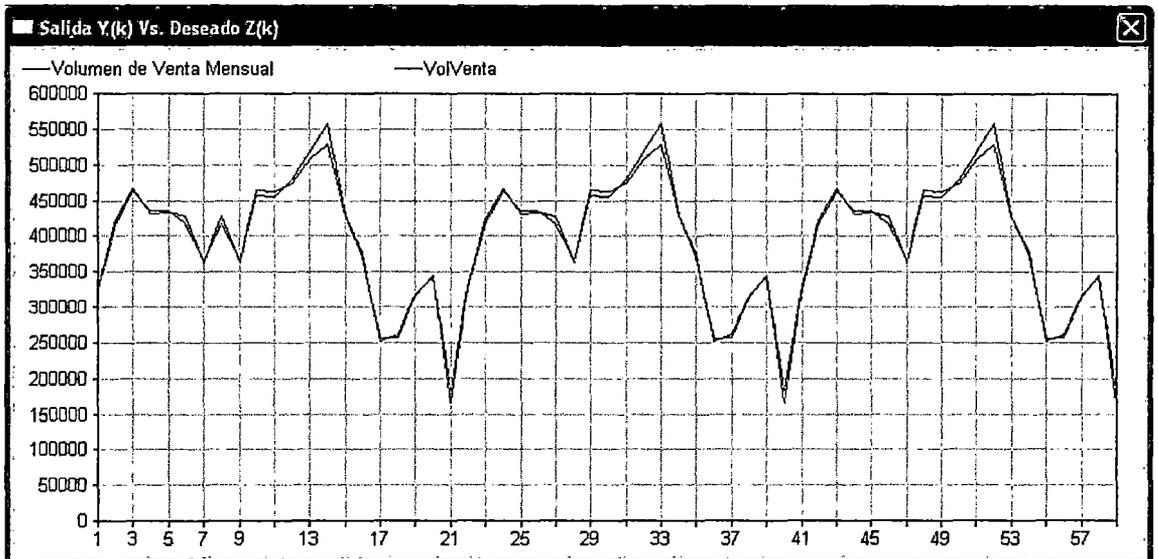


Figura 4.10. Ajuste de la data real de ventas con el pronóstico de la RNA recurrente

En la figura 4.10 se observa que el pronóstico de la RNA recurrente tiene una aproximación bastante cerca de la data real del cual se deduce que la RNA ha logrado un aprendizaje óptimo logrando ajustarse con un error mínimo a la data histórica real.

Desempeño de Modelo	
Parámetros de Optimización	
<b>MSE</b>	0.001598127758
<b>NMSE</b>	0.008113294720
<b>r</b>	0.996276922960
<b>% Error</b>	2.658849869872
<b>AIC</b>	-7.896426678347
<b>MDL</b>	-0.685444395115

Figura 4.11. Desempeño del modelo de RNA recurrente

En la figura 4.11 se presenta seis parámetros de los cuales cuatro de ellos son indispensables analizar para validar el modelo.

Desviación Estándar Media (MSE): en la figura 4.11 se observa que el MSE es 0.001598127758 del cual se deduce que el promedio de las desviaciones del error es muy aceptable.

Error cuadrático medio (NMSE): en la figura 4.11 se observa que el error cuadrático medio es de 0.008116294720, por lo tanto se concluye que la RNA ha logrado un aprendizaje óptimo.

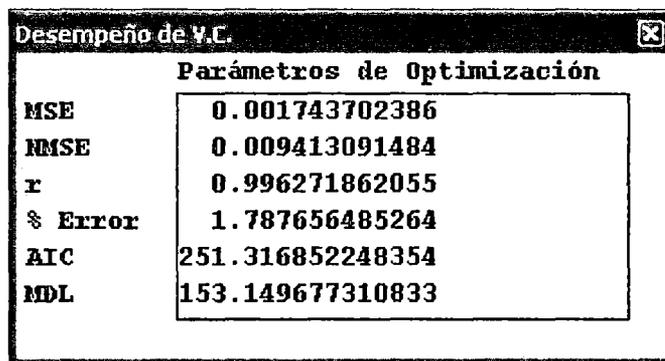
Grado de relación (r): en la figura 4.11 también se presenta el grado de relación que existe entre la data real y la data pronosticada por RNA y el grado de relación es de 0.996276922960 el cual nos dice que existe una relación positiva y casi perfecta entre la data real y la pronosticada. Este estadístico también refuerza la estabilidad de la RNA recurrente.

#### **4.4.1.3 TESTEO DE RNA RECURRENTE**

Para testear la RNA se utiliza la técnica de Cross Validation (validación cruzada). El testeo consiste en seleccionar un grupo de la data histórica y compararlo con el pronóstico que realiza la RNA, lo que se espera que la

diferencia de la data real y la pronosticada sea menor que el error aceptado.

Para testear esta RNA se trabajó con 20 datos y se obtuvo los siguientes resultados que se muestran en la figura 4.12.



The image shows a screenshot of a software window titled "Desempeño de Y.C." with a close button in the top right corner. Inside the window, there is a table of optimization parameters. The table has two columns: the parameter name and its numerical value. The parameters listed are MSE, NMSE, r, % Error, AIC, and MDL.

Parámetros de Optimización	
MSE	0.001743702386
NMSE	0.009413091484
r	0.996271862055
% Error	1.787656485264
AIC	251.316852248354
MDL	153.149677310833

Figura 4.12 Desempeño de la RNA - Testeo

Desviación Estándar Media (MSE): en la figura 4.12 se observa que el MSE es 0.00174372386 del cual se deduce que el promedio de las desviaciones del error es muy aceptable.

Error cuadrático medio (NMSE): en la figura 4.12 se observa que el error cuadrático medio es de 0.00941391484, por lo tanto se concluye que la RNA ha logrado un aprendizaje óptimo.

Grado de relación (r): en la figura 4.12 también se presenta el grado de relación que existe entre la data real y la data pronosticada por RNA y el grado de relación es de 0.996271862055 el cual nos dice que existe una

relación positiva y casi perfecta entre la data real y la pronosticada.

% Error: el porcentaje de error que presenta es de 1.787656485264, del cual se deduce que la RNA ha logrado predecir con certeza en un 98.2%.

#### **4.4.2. ARQUITECTURA PERCEPTRON MULTICAPA DE LA RNA RECURRENTE PARA PRONÓSTICO**

Edgar N. Sánchez (2006) manifiesta que el perceptrón multicapa recurrente siempre es más efectivo con una sola capa oculta.

Naturalmente se tenía que verificar esta hipótesis puesto que teóricamente el perceptrón multicapa tiene mayor precisión a medida de acuerdo al número de capas ocultas.

Para probar esta hipótesis y así descartar la arquitectura genérica para el pronóstico de la variable en estudio, en la figura 4.13 se muestra un diagrama a bloques de otra RNA recurrente genérica, llamada modelo en espacio de estado. Las neuronas ocultas definen el estado de la red. La salida de la capa oculta es retroalimentada a la capa de entrada a través de un banco de retardos unitarios. La capa de entrada consiste en la concatenación de los nodos de retroalimentación y los nodos fuente.

Los detalles del modelo se presentan en el marco teórico de este trabajo de investigación.

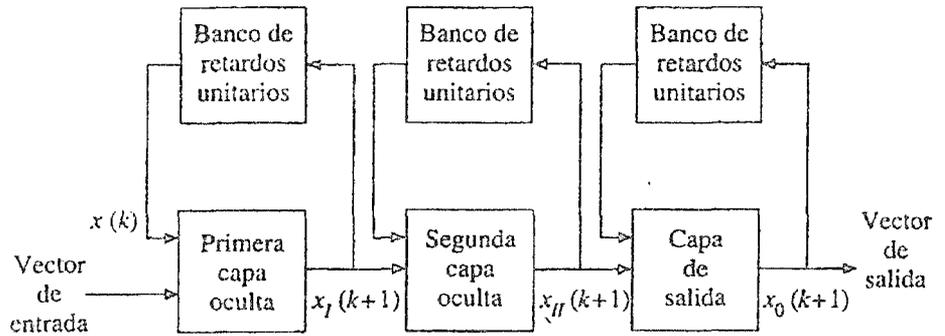


Figura 4.13 – Arquitectura de RNA Perceptrón multicapa recurrente.

A continuación se define los parámetros necesarios de esta arquitectura aplicado al pronóstico de las variables de marketing y ventas.

Donde:

Capa de entrada:

Vector de entrada: se tiene 8 variables mencionadas en la sección 4.1

Vector de salida: 25 salidas

En la capa de entrada se define el Banco de Retardos Unitarios

Primera Capa Oculta

Vector de entrada: 3

Vector de salida: 3

Función de Transferencia: Tangente Hiperbólico

Segunda Capa Oculta

Vector de entrada: 3

Vector de salida: 3

Función de Transferencia: Tangente Hiperbólico

Capa de salida:

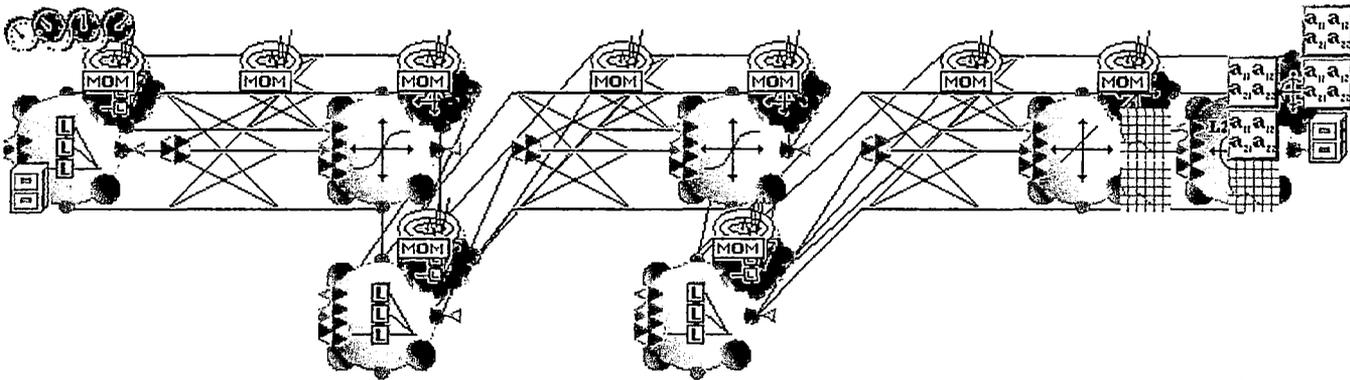
Vector de entrada: 3

Vector de salida: 1

Función de Transferencia: Bias

Pesos Iniciales: Aleatorios

Para obtener la red neuronal artificial recurrente óptima que se ajusta al comportamiento de las variables de marketing y ventas se trabajó el software de investigación de Neuro Solution en el cual se ha construido la arquitectura de Elman. En la figura 4.14 se presenta la Red Neuronal Recurrente configurada en Neuro Solution.



Para entender la funcionalidad de cada componente de la RNA Recurrente que se presenta en la figura 4.14 ver anexo.

#### 4.4.2.1 ENTRENAMIENTO DE LA RNA PERCEPTRON MULTICAPA RECURRENTE

Para entrenar a la red es necesario inicializar los pesos de toda la red; y para este caso la inicialización de los pesos es aleatoria.

El factor de aprendizaje (alfa) será de 0.7 que es el más recomendado.

El entrenamiento es de 10,000 épocas.

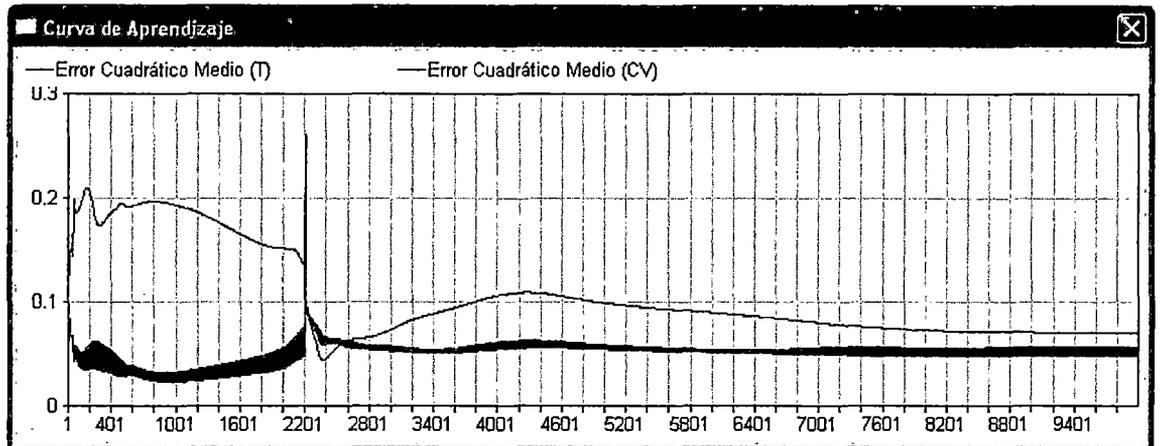


Figura 4.15: Curva de aprendizaje de la RNA Genérica Recurrente

En la figura 4.15 se observa como el error cuadrático medio empieza a decrecer a medida que se va entrenando la red, sin embargo a partir de la época de entrenamiento 3400 el error empieza a crecer. Además, observando la curva de aprendizaje, el error tiene un crecimiento leve con una tendencia positiva hasta la época 10,000. Finalmente la red no logra un aprendizaje óptimo pues el error cuadrático medio llegó a 0.057027037902 en la época de entrenamiento 10,000. Además, también se puede ver en la figura 4.16 que existe mucha diferencia entre la data deseada (data real) y la salida de la RNA Recurrente. La línea azul representa

la data histórica de ventas y la roja la data pronosticada por la red neuronal.

Por otra parte se observa que en la figura 4.16 que el pronóstico de la RNA genérica recurrente presenta en varios tramos una diferencia no aceptable con la data histórica. Esto refuerza que el error cuadrático medio no es lo suficientemente aceptable para utilizar esta arquitectura en el pronóstico de las variables de marketing y ventas.

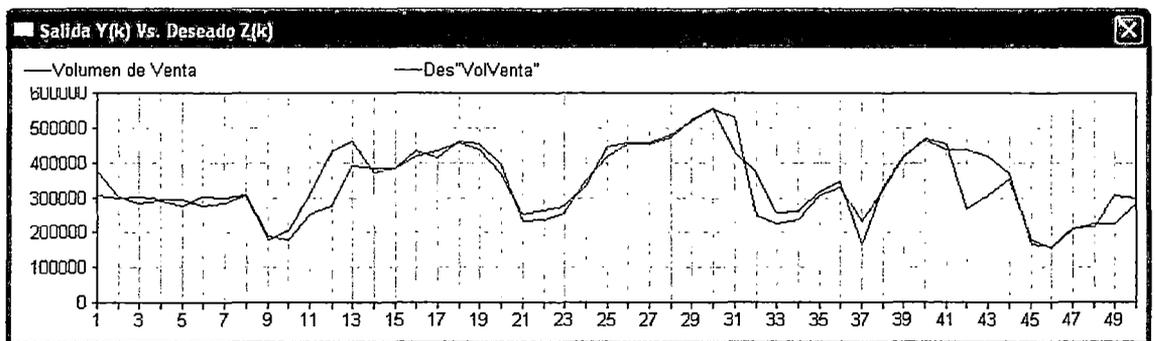


Figura 4.16: Comparación de la predicción de la RNA genérica recurrente con la data real

## 4.5 IMPLEMENTACIÓN DE LOS MODELOS DE PRONÓSTICO PARA LA TOMA DE DECISIONES

### 4.5.1 MODELO ESTADÍSTICO DE SERIES DE TIEMPO

Para tomar decisiones respecto a qué modelo de pronóstico se debe implementar; se ha diseñado dos fichas técnicas para cada modelo de pronóstico que reúnen la información relevante para la toma de decisiones.

En la ficha del modelo de pronóstico se presenta la información de la variable de estudio, para este caso el comportamiento de las ventas. Además también contiene los métodos de series de tiempo que se han utilizado del cual se elige el mejor.

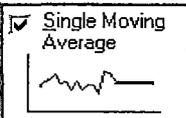
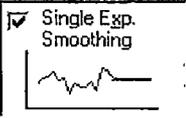
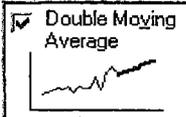
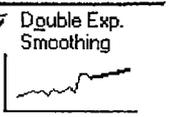
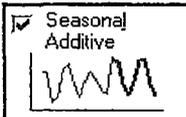
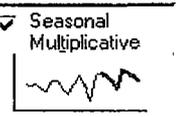
En la segunda ficha se hace la documentación del análisis y el detalle del pronóstico de la variable de estudio así como su gráfico correspondiente.

#### **4.5.1.1 FICHA DE INFORMACIÓN GENERAL DE LA VARIABLE**

##### **OBJETIVO: VOLUMEN DE VENTAS**

A continuación se presenta en la ficha técnica el análisis de los resultados del método de series de tiempo.

## Ficha del Modelo de Pronóstico con Series de Tiempo

<b>MODELO DE PRONÓSTICO</b>		Tipo de Escenario	
<b>MODELO ESTADÍSTICO</b>		<input type="radio"/> Probable <input checked="" type="radio"/> Alternativo	
Tipo de Actitud		Breve Descripción de la Actitud a Seguir	
<input type="radio"/> Pre-Activa <input checked="" type="radio"/> Pro-Activa			
<b>Actor(es) Sociales/Stakeholders/Grupos de Interes</b>			
1. Gerencia Ventas		3. Gerencia Comercial	
2. Gerencia de Marketing		4. Gerencia General	
<b>TECNICA DE PRONÓSTICO</b>		<i>Series de Tiempo, Regresión Lineal</i>	
<b>PERIODO DE ANÁLISIS:</b>		<i>Mensual</i>	
<b>PUNTOS DE CONTROL:</b>		<i>Fin de Mes</i>	
<b>OBJETIVO(S):</b>		<i>Pronóstico, Tendencias y Ciclos</i>	
Padrino del Modelo - Sponsor		Gerente Usuario (Area de Interes)	
Gerencia Financiera de Panificadora		Gerencia de Marketing y Ventas	
Proveedor del Servicio (Responsable del Pronóstico)		Responsable de Data Histórica (Fuente)	
Departamento de I + D		Responsable de datamart de Ventas	
<b>RESUMEN DE LA TECNICA:</b>			
El método de suavizamiento exponencial doble (Double Exponential Smoothing) tiene la menor desviación media (MAD) y el menor error cuadrático medio (RMSE) frente a los demás métodos, del cual se deduce que este método es el que tiene menos error en el pronóstico de ventas.			
<b>MÉTODOS DE PRONOSTICO - :</b>			
<b>MÉTODOS NO ESTACIONALES</b>			
<b>Single Movil Average</b> <input checked="" type="checkbox"/> Single Moving Average 	<b>Single Exp. Smoothing</b> <input checked="" type="checkbox"/> Single Exp. Smoothing 		
<b>Double Moving Averde</b> <input checked="" type="checkbox"/> Double Moving Average 	<b>Double Exp. Smoothing</b> <input checked="" type="checkbox"/> Double Exp. Smoothing 		
<b>MÉTODOS ESTACIONALES</b>			
<b>Seasonal Additive</b> <input checked="" type="checkbox"/> Seasonal Additive 	<b>Seasonal Multiplicative</b> <input checked="" type="checkbox"/> Seasonal Multiplicative 		
<b>Holt-Winters' Additive</b> <input checked="" type="checkbox"/> Holt-Winters' Additive 	<b>Holt-Winters' Multiplicative</b> <input checked="" type="checkbox"/> Holt-Winters' Multiplicative 		
Estado de Modelo			
<input type="radio"/> En Construcción <input checked="" type="radio"/> En Propuesta <input type="radio"/> En Ejecución <input type="radio"/> Archivado			

#### **4.5.1.2 INFORMACIÓN DETALLADA DEL ANÁLISIS DE LOS RESULTADOS DE LA VARIABLE OBJETIVO DE PRONÓSTICO: VOLUMEN DE VENTAS**

La información detallada del pronóstico y su análisis respectivo se registra en la ficha técnica el cual sirve como un documento de registro y archivo.

De acuerdo a los resultados que se observa en la ficha técnica del método de series de tiempo, en particular, no se sería el modelo apropiado para tomar decisiones.

## Ficha Técnica del mejor método que se ajusta a la variable de estudio

<b>OBJETIVO</b>	Pronosticar las ventas mensuales de los productos de la línea alfajores para los cuatro primeros meses del 2010					
<b>INDICADOR</b>	<b>HORIZONTE DE TIEMPO</b>			<b>PARAMETROS DE DESEMPEÑO:</b>		
	<b>Comienzo</b>	<b>Fin</b>	<b>Nro de Per.</b>	<b>RMSE</b>	<b>MAD</b>	<b>CONFIANZA</b>
	Dic, 2005	Dic, 2009	49	64303	45218	95%

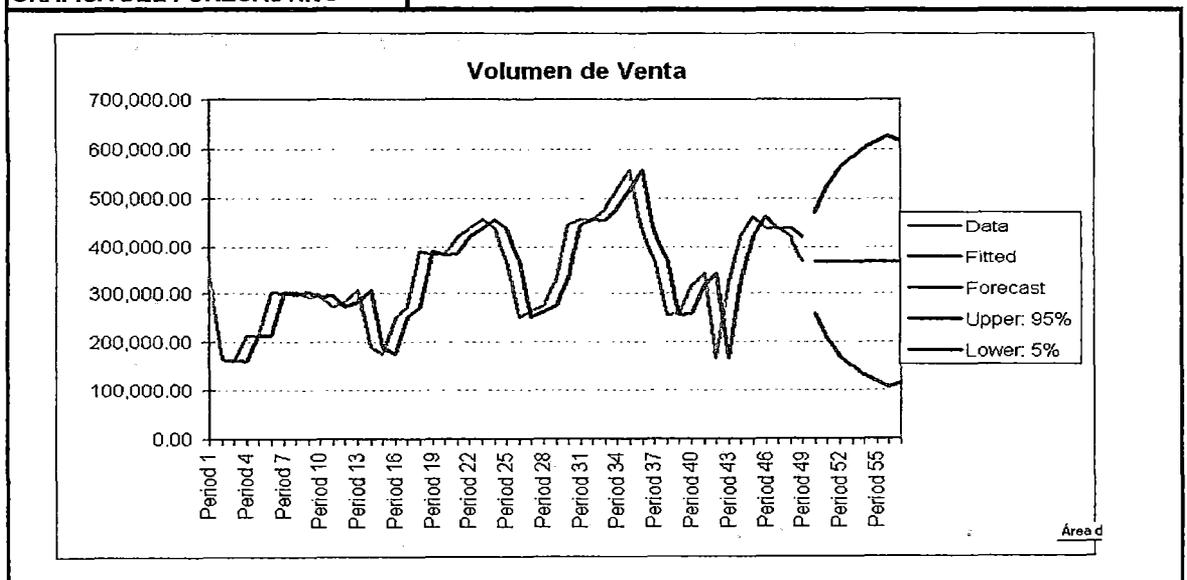
<b>ANALISIS</b>	Tendencia	El comportamiento de las ventas se observa una tendencia positiva en los 3 primeros años y el último año tiene existe una tendencia negativa.
	Ciclos	El comportamiento de las ventas no presenta ciclos.
	Predicción	El promedio de ventas para los cuatro primeros meses del 2010 es de 366 mil nuevos soles.

PERIODOS DE PRONÓSTICO	INTERVALO DE CONFIANZA			PRONÓSTICO - 2010		
	INFERIOR	PRONOSTICO	SUPERIOR	Periodos	Venta Real	Error
Enero	259,554.21	<b>366,468.86</b>	473,383.52	Enero	S/. 288,246.63	S/. 78,222.24
Febrero	208,525.24	<b>366,501.30</b>	524,477.36	Febrero	S/. 273,139.00	S/. 93,362.30
Marzo	172,276.12	<b>366,533.74</b>	560,791.35	Marzo	S/. 312,000.50	S/. 54,533.24
Abril	149,361.54	<b>366,566.17</b>	583,770.81	Abril	S/. 350,200.00	S/. 16,366.17

### RECOMENDACIONES

De acuerdo a los resultados obtenidos, se observa que el método de series de tiempo presenta un margen de error no aceptable. Sin embargo las ventas reales de los cuatro meses en las cuales se ha hecho el pronóstico, se encuentra dentro del intervalo de confianza que ha sido calculado por el modelo estadístico a un 95% el nivel superior y 5% el nivel inferior. Una de las desventajas de este modelo es que el rango de los intervalos de confianza son muy amplios y no es mucha utilidad para la toma de decisiones.

### GRAFICA DEL FORECASTING



Estado de Escenario		
<input type="radio"/> En Ejecución	<input checked="" type="radio"/> En Estudio	<input type="radio"/> Archivado

Revisión:	3
Fecha:	008/05/2010

## 4.5.2 MODELO DE RNA RECURRENTE PARA SERIES DE TIEMPO

### 4.5.2.1 FICHA DE INFORMACIÓN GENERAL DEL MODELO DE RNA RECURRENTE

A continuación se presenta la información del modelo de RNA recurrentes

<b>MODELO DE PRONÓSTICO</b>		Tipo de Escenario	
<b>RNA RECURRENTE</b>		<input checked="" type="radio"/> <b>Probable</b> <input type="radio"/> <b>Alternativo</b>	
Tipo de Actitud	Breve Descripción de la Actitud a Seguir		
<input type="radio"/> <b>Pre-Activa</b> <input checked="" type="radio"/> <b>Pro-Activa</b>	El escenario que permite construir es modelo de pronostico basado en RNA concurrentes es de tipo PROBABLE el cual nos permite tener una actitud pro-activa.		
<b>Actor(es) Sociales/Stakeholders/Grupos de Interes</b>			
1. Gerencia Ventas		3. Gerencia Comercial	
2. Gerencia de Marketing		4. Gerencia General	
<b>TECNICA DE PRONÓSTICO</b>		<b>RNA RECURRENTE</b>	
PERIODO DE ANÁLISIS:		<b>Mensual</b>	
PUNTOS DE CONTROL:		<b>Fin de Mes</b>	
OBJETIVO(S):		<b>Pronóstico, Tendencias y Ciclos</b>	
Padrino del Modelo - Sponsor		Gerente Usuario (Area de Interes)	
Gerencia Financiera de Panificadora		Gerencia de Marketing y Ventas	
Proveedor del Servicio (Responsable del Pronóstico)		Responsable de Data Histórica (Fuente)	
Departamento de I + D		Responsable de datamart de Ventas	
<b>RESUMEN DE LA TECNICA:</b>			
Luego de las pruebas realizadas con diferentes arquitecturas de una RNA concurrente, se ha concluido que la arquitectura con genérica del perceptrón multicapa es la que se ajusta con mayor precisión al comportamiento de las variables de Marketing y Ventas.			
<b>METODOS DE PRONOSTICO - :</b>			
<b>ARQUITECTURA SIMPLE DE RNA RECURRENTE</b>			
<b>MODELO CONFIGURADO EN NEURO SOLUTION V 5.0</b>			
Estado de Modelo			
<input type="radio"/> En Construcción <input checked="" type="radio"/> En Propuesta <input type="radio"/> En Ejecución <input type="radio"/> Archivado			

### 4.5.2.2 INFORMACIÓN DETALLADA DEL ANÁLISIS DE LOS RESULTADOS DE LA VARIABLE OBJETIVO DE PRONÓSTICO CON EL MODELO DE RNA RECURRENTE.

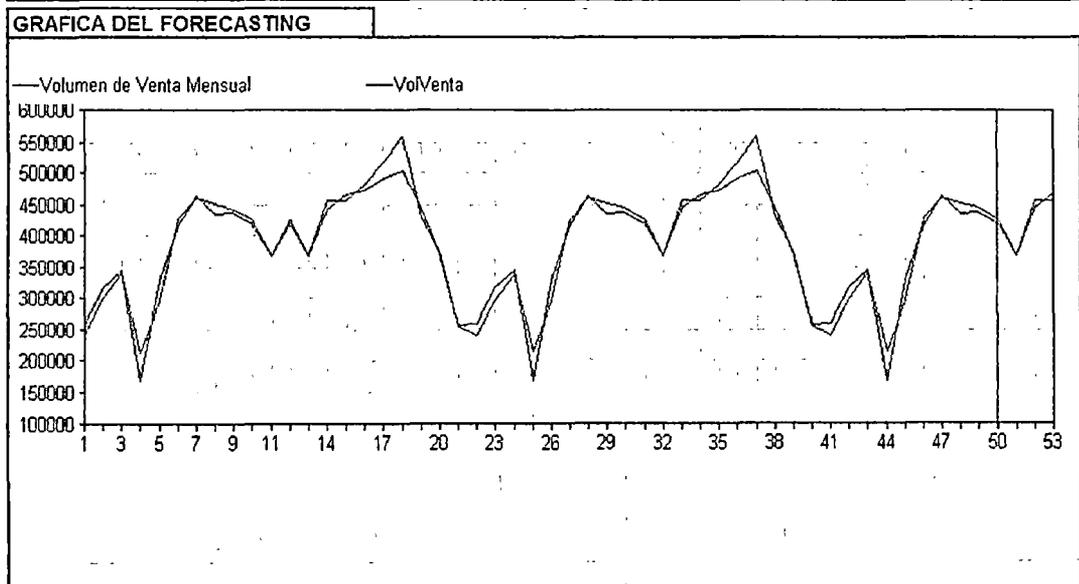
<b>OBJETIVO</b>	Pronosticar las ventas mensuales de los productos de la línea alfajores para los cuatro primeros meses del 2010					
<b>INDICADOR</b>	<b>HORIZONTE DE TIEMPO</b>			<b>PARÁMETROS DE DESEMPEÑO:</b>		
	<b>Comienzo</b>	<b>Fin</b>	<b>Nro de Per.</b>	<b>MSE</b>	<b>NMSE</b>	<b>ERROR(%)</b>
	Dic, 2005	Dic, 2009	49	0.001598128	0.008116295	2.6588%

<b>ANÁLISIS</b>	Tendencia	EN el comportamiento de las ventas se observa una tendencia positiva en los 3 primeros años y el último año existe una tendencia negativa.
	Ciclos	El comportamiento de las ventas no presenta ciclos.
	Predicción	La predicción de las ventas se realizará para los cuatro primeros meses del años 2010.

MESES	MODELO SIMPLE (ELMAN)			MODELO GENERICO		
	Data Real	Pronóstico	Error	Data Real	Pronóstico	Error
Enero	290.943.94	289,526.00	1.417.94	290943.94	278,568.00	12.375.94
Febrero	274.995.14	280,568.00	5.572.86	274995.14	259,845.00	15.150.14
Marzo	356,957.72	345,236.00	11.721.72	356957.72	342,356.00	14,601.72
Abril	339,459.14	340,256.00	796.86	339459.14	335,684.00	3.775.14

**RECOMENDACIONES**

De acuerdo a los resultado obtenidos, se observa que el modelo genérico presenta un margen de error no aceptable. Sin embargo el modelo simple que solo tiene una capa oculta es el que mejor se ajusta al comportamiento de las variables de marketing y ventas. Entonces, para realizar pronóstico de la ventas, se recomienda utilizar modelo simple de Elman que es el que tiene una mayor precisión en el pronóstico de las ventas.



Estado de Escenario

En Ejecución    
 En Estudio    
 Archivado

Revisión: 3

Fecha: 008/05/2010

#### 4.5.3 FACTIBILIDAD DE IMPLEMENTACIÓN DEL MODELO DE PRONÓSTICO

Para poner en producción el modelo de predicción es necesario considerar varios aspectos el cual se detalla en el siguiente cuadro:

<b>PERSONAL</b>	
Especialista en Redes Neuronales	3,000.00
Especialista en Data Warehouse	5,000.00
Programador en SQL BI y Visual.NET	5,000.00
<b>ARQUITECTURA</b>	
Equipos	
2 Computadoras	5,000.00
Impresora HP LaserJet 2410	500.00
Soporte de SW	
Software licenciado DE Neuro Solution V5.0	1,800.00
SQL Server 2008	2,200.00
<b>SERVICIOS</b>	
INTERNET (www, ftp.)	30.00
Fotocopias	200.00
Consultoría	2,500.00
<b>Total</b>	<b>Sl. 25,230.00</b>

Fuente: Elaboración propia

#### 4.6 CONTRASTACIÓN DE LA HIPOTESIS

**Cuadro 4.5 Estadísticos para muestras relacionadas: Series de Tiempo Vs RNAC - Elman**

**Estadísticos de muestras relacionadas**

	Media	N	Desviación típ.	Error típ. de la media
Series de Tiempo	45217.69	47	46213.51457	6740.93391
RNA Concurrentes	15689.39	47	15492.47409	2259.80960

En el cuadro 4.5 se observa que el promedio del error del pronóstico de ventas con series de tiempo es de 45,217.69, y el error promedio del pronóstico de ventas con Redes Neuronales Concurrentes-Modelo de Elman, es de 15,689.39.

**Cuadro 4.6 Prueba t-student para comparar el error promedio del pronóstico de la ventas del modelo de series de tiempo con el modelo de RNA Concurrentes-Elman**

	Diferencias relacionadas					t	gl	Sig. (bilateral)
	Media	Desviación típ.	Error típ. de la media	95% Intervalo de confianza para la diferencia				
				Inferior	Superior			
Series - RNAC	29528.30	36616.31693	5341.03876	18777.35	40279.25	5.529	46	.000

En el cuadro 4.6 se observa que la diferencia de medias del error del pronóstico de ventas entre el modelo de series de tiempo y RNA Concurrentes-Elman es de 29,528.30 con un nivel de significancia de 0.000 que es menor a 0.05; de este resultado se confirma que el Modelo de Redes Neuronales Artificiales Recurrentes con la arquitectura de Elman tiene mayor precisión en la Predicción frente a las modelo estadístico de series de tiempo aplicadas a las variables estratégicas de Marketing y Ventas de la Industria de Panificación.

**Cuadro: 4.7 Estadísticos para muestras relacionadas: Regresión Lineal Vs RNAC - Elman**

	Media	N	Desviación típ.	Error típ. de la media
Regresión Lineal	68748.65	47	49837.41188	7269.53366
RNAC - Elman	15689.39	47	15492.47409	2259.80960

En el cuadro 4.7 se observa que el promedio del error del pronóstico de ventas con regresión lineal es de 68,748.65; y el error promedio del pronóstico de ventas con Redes Neuronales Concurrentes-Modelo de Elman, es de 15,689.39.

**Cuadro: 4.8 Prueba t-student para comparar el error promedio del pronóstico de las ventas del modelo de regresión lineal con el modelo de RNA Concurrentes-Elman**

	Diferencias relacionadas					t	gl	Sig. (bilateral)
	Media	Desviación típ.	Error típ. de la media	95% Intervalo de confianza para la diferencia				
				Inferior	Superior			
Regresión Lineal Vs. RNAC - Elman	53059.26	48915.40054	7135.04448	38697.16	67421.36	7.44	46	.000

En el cuadro 4.8 se observa que la diferencia de medias del error del pronóstico de ventas entre el modelo de regresión lineal y RNA Concurrentes-Elman es de 53,059.26 con un nivel de significancia de 0.000 que es menor a 0.05; de este resultado se confirma que el Modelo de Redes Neuronales Artificiales Recurrentes con la arquitectura de Elman tiene mayor precisión en la Predicción frente al modelo estadístico de regresión lineal aplicadas a las variables estratégicas de Marketing y Ventas de la Industria de Panificación.

## **CONCLUSIONES Y RECOMENDACIONES**

### **CONCLUSIONES**

De acuerdo al análisis estadístico, las variables que tienen mayor influencia sobre las ventas son: las estaciones del año, la tendencia y las devoluciones.

La arquitectura de una RNA recurrente simple es la que se ajusta con mayor precisión al comportamiento de las variables de marketing y ventas frente a la arquitectura genérica de una RNA recurrente.

Debido a la poca cantidad de los periodos de data histórica, para entrenar a la red se necesita mayor cantidad de iteraciones.

El entrenamiento estático de la RNA recurrente no permite obtener un aprendizaje óptimo, puesto que los parámetros de desempeño son configurados por única vez. Sin embargo el entrenamiento dinámico de la RNA recurrente si permite obtener un aprendizaje óptimo ya que los parámetros de desempeño de la RNA varían en un rango determinado el

cual es controlado por algoritmos genéticos que permiten obtener una RNA con un alto nivel de performance.

Al comparar el pronóstico de las ventas utilizando los métodos de las series de tiempo, regresión lineal y el modelo de RNA recurrentes, se concluye que las RNA recurrentes tienen mayor precisión en el pronóstico frente a los modelos de series de tiempo y regresión lineal.

Al hacer pronóstico con los métodos estadísticos de series de tiempo y regresión lineal, se obtiene un error el cual una vez obtenido ya no es posible reducir dicho error. Sin embargo las RNA recurrentes por su naturaleza, si se obtiene un error no aceptable, a medida que se hacen más iteraciones de entrenamiento, el error va reduciendo cada vez más hasta llegar por debajo del error aceptable.

## **RECOMENDACIONES**

Para darle continuidad a este tipo de pronóstico de las variables de marketing y ventas, es necesario delegar responsabilidades de acuerdo a los roles para garantizar la presión y exactitud de los datos a pronosticar.

Puesto que para el pronóstico se necesita una data histórica procesada de acuerdo al tiempo; se recomienda crear el departamento de BI (Business Intelligence) para crear un datamart de las variables de marketing y ventas el cual pueden garantizar el procesamiento de los datos en diferentes dimensiones del tiempo.

Los responsables del área de marketing y ventas deben hacer un mayor análisis de las variables: estaciones del año, la tendencia y las devoluciones ya que estas son los que tienen mayor repercusión en el volumen de ventas.

Debido a su mejor desempeño de la arquitectura de una RNA recurrente simple el cual se ajusta con mayor precisión al comportamiento de las variables de marketing, ventas se recomienda implementar este modelo en un sistema de información ejecutivo para los directivos del área de marketing y ventas.

Se recomienda analizar en un periodo semanal las variables de estudio, ya que al tener mayor cantidad de data histórica, la red puede tener mayor precisión en su pronóstico.

Las fichas diseñadas para la documentación de los modelos de pronóstico, se deben actualizar cada vez que se hace un nuevo pronóstico ya que permite visualizar la evolución del modelo en el tiempo.

Solo la ficha donde figura el detalle del pronóstico de las variables de estudio se debe entregar a los directivos ya que es ahí donde va la información que ellos necesitan para la toma de decisiones.



## GLOSARIO DE TERMINOS

**Axón.-** son prolongaciones de las neuronas especializadas en conducir el impulso nervioso desde el cuerpo celular o soma hacia otra célula

**Algoritmos genéticos.-** son métodos adaptativos que pueden usarse para resolver problemas de búsqueda y optimización. Están basados en el proceso genético de los organismos vivos.

**Contrastación.-** distintos procesos y actividades que el científico realiza para la justificación de la verdad de sus hipótesis ante la comunidad científica. La verificación sirve para garantizar la verdad de una teoría.

**Dendrita.-** prolongaciones protoplásmicas ramificadas, bastante cortas, de la neurona. Son terminales de las neuronas; y están implicadas en la recepción de los estímulos, pues sirven como receptores de impulsos nerviosos provenientes desde un axón perteneciente a otra neurona

**Hiperplano.-** Un hiperplano es un concepto de geometría. Es una generalización del concepto de plano

**Hipótesis.-** proposición aceptable que ha sido formulada a través de la recolección de información y datos, aunque no está confirmada sirve para responder de forma tentativa a un problema con base científica.

**Monitoreo.-** Su origen se encuentra en monitor, que es un aparato que toma imágenes de instalaciones filmadoras o sensores y que permite visualizar algo en una pantalla. El monitor, por lo tanto, ayuda a controlar o supervisar una situación.

**Nivel de significancia.-** Valor especificado de probabilidad usado para establecer el límite de aceptación o rechazo de una hipótesis en el análisis estadístico. Comúnmente se usan los niveles de 1% y de 5%.

**Oscilación.-** variación, perturbación o fluctuación en el tiempo de un medio o sistema. Si el fenómeno se repite, se habla de oscilación periódica.

**Parámetro.-** dato que es tomado como necesario para analizar o valorar una situación. A partir del parámetro, una determinada circunstancia puede entenderse o situarse en perspectiva.

**Perceptrón multicapa.-** 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.

**Peso Sináptico.-** En neurología y informática, **peso sináptico** refiere a la fuerza o a la amplitud de una conexión entre dos nodos.

**Pre sináptica.-** Se dice de lo que está próximo a la sinapsis. Se trata de los botones sinápticos axonales (que contactan con los correspondientes de las dendritas) y liberan un neurotransmisor en la hendidura sináptica.

**Prototipo.**- representación limitada del diseño de un producto que permite a las partes responsables de su creación experimentar, probarlo en situaciones reales y explorar su uso.

**Redes Neuronales Artificiales.**- son un paradigma de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso de los animales. Se trata de un sistema de interconexión de neuronas en una red que colabora para producir un estímulo de salida.

**Redes Neuronales Artificiales Recurrentes.**- son redes neuronales que presentan uno o más ciclos en el grafo definido por las interconexiones de sus unidades de procesamiento. La existencia de estos ciclos les permite trabajar de forma innata con secuencias temporales. Las redes recurrentes son sistemas dinámicos no lineales capaces de descubrir regularidades temporales en las secuencias procesadas y pueden aplicarse, por lo tanto, a multitud de tareas de procesamiento de este tipo de secuencias.

**Regresión lineal.**- método matemático que modeliza la relación entre una variable dependiente  $Y$ , las variables independientes  $X_i$  y un término aleatorio.

**Retroalimentación.**- mecanismo muy importante que aumenta el valor de algunas reglas de actuación y disminuye el valor de otras.

**Simulación.**- Simulación es una técnica numérica para conducir experimentos en una computadora digital. Estos experimentos comprenden ciertos tipos de relaciones matemáticas y lógicas, las cuales son necesarias para describir el comportamiento y la estructura de sistemas complejos del mundo real a través de largos períodos.

**Sinapsis.**- unión intercelular especializada entre neuronas. En estos contactos se lleva a cabo la transmisión del impulso nervioso. Éste se inicia con una descarga química que origina una corriente eléctrica en la membrana de la célula pre sináptica.

**Soma.**- es el cuerpo de una neurona, el cual contiene el núcleo y los nucléolos de la neurona

**Tangente hiperbólico.**- se define como el cociente entre el seno hiperbólico y el coseno hiperbólico del número real  $x$ .

## REFERENCIAS BIBLIOGRÁFICA

1. José R. Hilera/Víctor J. Martínez. REDES NEURONALES ARTIFICIALES. Edición ADDISON-WESLEY IBEROAMERICANA, 2000
2. Pedro Isasi Viñuela. Redes de Neuronas Artificiales. Ediciones PEARSON, Prentice Hall, 2005.
3. Aristizábal M. (2005) Evaluación asimétrica de una red neuronal artificial [<http://ideas.repec.org/p/bdr/borrec/377.html>] Consultado el 15 de enero del 2007.
4. Cotter, A.S.: "the complexity of theorem and its application to neural networks", IEEE Transactions on Neural Networks, vol. 1, num. 4.
5. AstraZeneca (2002) Aplicación de Forecasting a cinco años de AstraZeneca [[http://www.bgsonline.com/pdfs/casos\\_estudio/Aplicacion\\_forecasting\\_AstraZeneca.PDF](http://www.bgsonline.com/pdfs/casos_estudio/Aplicacion_forecasting_AstraZeneca.PDF)] Consultado el 16 de enero del 2007.

6. Barca R. (2004) Pronóstico de Ventas  
[[http://www.barcaauditores.com/Articulos/Pronostico\\_de\\_ventas.htm](http://www.barcaauditores.com/Articulos/Pronostico_de_ventas.htm)  
] Consultado el 24 de enero del 2007.
7. Benito M. (2002) Predicción mediante Redes Neuronales Artificiales en el entorno de un Sistema de Información Geográfica  
[<http://www.uam.es/proyectosinv/Mclim/pdf/MScMarta.pdf>]  
Consultado el 16 de enero del 2007.
8. Collantes y Otros (2004) Predicción con redes neuronales artificiales: comparación con las metodologías de box y jenkins  
[[http://www2.scielo.org.ve/scielo.php?script=sci\\_arttext&pid=S0254-07702004000300002&lng=pt&nrm=iso](http://www2.scielo.org.ve/scielo.php?script=sci_arttext&pid=S0254-07702004000300002&lng=pt&nrm=iso)] Consultado el 22 de enero del 2007.
9. DeGuate. (2003) Desarrollo del pronóstico de ventas  
[<http://www.deguate.com/infocentros/gerencia/mercadeo/mk27.htm>]  
Consultado el 24 de enero del 2007.
10. Global Watch (2003) International Workshop on Crop Monitoring and Yield Forecasting: Tools for Early Warning  
[[http://mars.jrc.it/marsfood/Meetings/2002-11\\_Cordoba/Presentations/cherlet.pdf](http://mars.jrc.it/marsfood/Meetings/2002-11_Cordoba/Presentations/cherlet.pdf)] Consultado el 15 de enero del 2007.
11. Grupo Mixto de Meteorología Aplicada (2005) Proyectos sobre Cambio Climático Regional  
[<http://grupos.unican.es/ai/meteo/proyectos/clima/CambioClima.pdf>]  
Consultado el 18 de enero del 2007.

12. Hernández Sampieri R & Fernández Collado (2003). Metodología de la Investigación. Editorial McGrawHill. México.
13. Montes J. (2006) Sistemas Expertos (SE).  
[<http://www.gestiopolis.com/canales2/gerencia/1/sisexp.htm>]  
Consultado el 15 de marzo del 2006.
14. Mora J. (2004) La inteligencia artificial aplicada a la valoración de inmuebles.  
[[http://www.catastro.meh.es/esp/publicaciones/ct/ct50/\\_2E.pdf](http://www.catastro.meh.es/esp/publicaciones/ct/ct50/_2E.pdf)]  
Consultado el 15 de enero del 2007.
15. Ochoa A. (2002) Métodos de investigación  
[<http://www.monografias.com/trabajos11/metods/metods.shtml>]  
Consultado el 10 de marzo del 2006.
16. Olmedo y Otros (2004) Utilización de Redes Neuronales en la Caracterización, Modelización y Predicción de Series Temporales Económicas en un Entorno Complejo.  
[<http://cabrillo.lsi.uned.es:8080/aepia/Uploads/23/52.pdf>] Consultado el 10 de enero del 2007.
17. Pilot (2001). Manual de Consulta Forecasting.  
[<http://www.programaempresa.com/empresa/empresa.nsf/0/e88d210e51f9371ac125705b002c66c9/>] Consultado el 10 de enero del 2007.
18. Pino y Parreño (2005) Aplicación de Redes Neuronales al pronóstico a corto plazo del Precio de la electricidad en España  
<http://cio2005.uniovi.es/cio2005/VerDocumento.do;jsessionid=45BE>

49CC72EB8DA0BDB56AA010E6ECC5?id=232&tipo=resumen]

Consultado el 16 de enero del 2007.

19. Rifo C. (2005) Documento de apoyo y referencia para la asignatura Planificación de la Producción  
[[http://weblogs.udp.cl/claudio.rifo/archivos/\(3565\)planificacion\\_de\\_la\\_Produccion.pdf](http://weblogs.udp.cl/claudio.rifo/archivos/(3565)planificacion_de_la_Produccion.pdf)] Consultado el 24 de enero del 2007.
20. Ruiz N. (2006) El observatorio como herramienta para la gestión de la información y del conocimiento.  
[[http://www.sela.org/sela/docs/selaiica/UCV\\_%20Prospectiva%20premisas%20conceptuales\\_NydiaRuiz.pdf](http://www.sela.org/sela/docs/selaiica/UCV_%20Prospectiva%20premisas%20conceptuales_NydiaRuiz.pdf)] Consultado el 10 de enero del 2007.
21. Salini y Pérez (2006) Time series analysis of atmosphere pollution data using artificial neural networks techniques  
[<http://www.scielo.cl/pdf/ingeniare/v14n3/art12.pdf>] Consultado el 18 de enero del 2007.
22. Serrano y Gallizo. Las redes neuronales artificiales en el tratamiento de la información financiera  
[<http://ciberconta.unizar.es/Biblioteca/0004/SerGall96.html>]  
Consultado el 22 de enero del 2007.
23. Stoner J. A. F., Freeman R. E., Daniel R. G. 1996. Administración. 6ta edición. México: Pearson / Prentice Hall. 740 p.
24. Tao y Lim (2001) Guidelines for Financial Forecasting with Neural Networks

[[http://www2.cs.uregina.ca/~jtyao/Papers/guide\\_iconip01.pdf](http://www2.cs.uregina.ca/~jtyao/Papers/guide_iconip01.pdf)]

Consultado el 18 de enero del 2007.

25. Vidal J. (2004) The future of wind energy is forecasting.

[<http://www.meteosim.com/premsa/energetica21.pdf>] Consultado el

9 de enero del 2007.

26. Vila D. (2006) Use of QPE Flash Flood Forecasting: Some experiences on the Cuareim River

[<http://www.nws.noaa.gov/iao/FFW/2006/Presentations/Session%204/VILA-IMN-COSTA%20RICA.ppt>] Consultado el 18 de enero del

2007.

27. Vinagre F. (2004) Identificación y clasificación de series temporales numéricas mediante redes neuronales.

[<http://cabierta.uchile.cl/revista/24/articulos/pdf/paper11.pdf>]

Consultado el 12 de enero del 2007.

28. Chambers, J. Mullick, S. Y Smith (2003) Cómo elegir la técnica de pronóstico correcta. D. Biblioteca Harvard.

29. Kazmier, Leonard. (1999) Estadística aplicada a la administración y la economía. Mc Graw-Hill

30. José R. Hilera, Víctor J. Martínez; Ra-ma, (1995). Redes Neuronales Artificiales: Fundamentos, modelos y aplicaciones.

31. Arbeleche Grela, S. (2005). Pronósticos de Negocios. Mexico: Itam.

32. Escalona Moreno, I. (2003). PCP. Mexico: Instituto Politécnico Nacional.

33. Escalona Moreno, I. (Lunes de Abril de 2003).  
www.monografias.com. Recuperado el Martes de Abril de 2010, de  
www.monografias.com:  
[<http://www.monografias.com/trabajos13/placo/placo.shtml>]
34. Garcia Moreno, J. (2010). Métodos Cuantitativos para  
Administración. Mexico: Publicaciones Adventure Works.
35. León Sanchez, D. p. (Martes de Noviembre de 2004).  
www.fce.unal.edu.co. Recuperado el Lunes de Junio de 2010, de  
www.fce.unal.edu.co:  
[[http://www.fce.unal.edu.co/uifce/newuifce/conf/documentos/crystal\\_](http://www.fce.unal.edu.co/uifce/newuifce/conf/documentos/crystal_ball.pdf)  
[ball.pdf](http://www.fce.unal.edu.co/uifce/newuifce/conf/documentos/crystal_ball.pdf)]
36. Management, C. R. (Jueves de Agosto de 2007).  
www.crmmexico.com. Recuperado el Martes de Junio de 2010, de  
www.crmmexico.com:  
[[http://crmexico.com/Calendario2009/Mejores%20practicas%20en](http://crmexico.com/Calendario2009/Mejores%20practicas%20en%20pronosticos.pdf)  
[%20pronosticos.pdf](http://crmexico.com/Calendario2009/Mejores%20practicas%20en%20pronosticos.pdf)]
37. Mendoza Zamora, G. (Jueves de Agosto de 2006).  
www.monografias.com. Recuperado el Lunes de Abril de 2010, de  
www.monografias.com:  
[<http://www.monografias.com/trabajos4/pronosticar/pronosticar.shtml>]
38. Ortiz Van Steenberghe, K. (Viernes de Julio de 2008).  
www.angelfire.com. Recuperado el Martes de Abril de 2010, de  
www.angelfire.com:

[<http://www.angelfire.com/un/ingenierias/castellano/pronosticos/pronosticos.html>].

39. Sapag Chain, N. (Lunes de Agosto de 2007).

[www.nassirsapag.blogspot.com](http://www.nassirsapag.blogspot.com). Recuperado el Martes de Abril de 2010, de [www.nassirsapag.blogspot.com](http://www.nassirsapag.blogspot.com):

[[http://nassirsapag.blogspot.com/2009\\_04\\_01\\_archive.html](http://nassirsapag.blogspot.com/2009_04_01_archive.html)].

40. Soto, L. (Martes de Abril de 2010). [www.mitecnologico.com](http://www.mitecnologico.com).

Recuperado el Martes de Abril de 2010, de [www.mitecnologico.com](http://www.mitecnologico.com):

[<http://www.mitecnologico.com/Main/PromediosMoviles>].

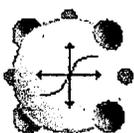
41. Stair Jr., R. (2006). *Métodos Cuantitativos para Negocios*. Buenos Aires: Prentice Hall.

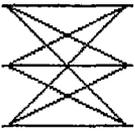
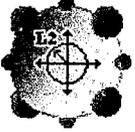
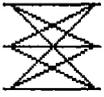
42. Toledo Muñoz, J. (1994). *Estadística*. Mexico: Alhambra Mexicana S.A.

## ANEXO

### A. PRICIPALES ICONOS DE NEUROSOLUTIONS

- Estos son los principales iconos con su descripción respectiva, que generalmente se utilizan en el uso del software NeruoSolutions para la simulación de redes neuronales artificiales RNA.

ICONO	NOMBRE	DESCRIPCIÓN	USO PRIMARIO
	<b>Axon</b>	Layer PE (procesador de elementos) función de transferencia de identidad.	Puede actuar como un placeholder para el componente del Archivo en el layer de entrada, o como un layer lineal de salida.
	<b>TanhAxon</b>	El Layer de PE está con función de transferencia hiperbólica (el rango de salida – 1 para 1)	Usado tras el layer de salida.

	<b>FullSynapse</b>	Multiplicación full de la matriz.	Conecta dos axon Layers
	<b>L2Criterion</b>	La diferencia ajustada entre la salida de sistema y la salida deseada	Computa el error entre la salida y la señal deseada, y lo pasa por alto para la red de backpropagación.
	<b>BackAxon</b>	Un SubLayer PE que está con función de transferencia de identidad.	Integrador para Axon "dual", para el uso en red de backpropagación.
	<b>BackTanhAxon</b>	El Layer PE está con función de transferencia que es la derivada de TanhAxon	Integrador TanhAxon "dual", para el uso en red de backpropagación.
	<b>BackFullSynapse</b>	Back full multiplicación de matrices	Integrador para FullSynapse acometedor "dual", para el uso en red de backpropagación.
	<b>BackCriteriaControl</b>	Entradas para la red de backpropagación.	Corresponde al Criterio, para el uso en red de backpropagación. Recibe error de Criterio.
	<b>Momentum</b>	La búsqueda de la gradiente con momento.	Actualiza pesos. El momento aumenta tasa efectiva de aprendizaje cuando el cambio del peso está consistentemente en la misma dirección.

	<b>StaticControl</b>	Controlador estático.	Controla la fase delantera de activación de red.
	<b>BackStaticControl</b>	El controlador estático de backpropagación	Controla la fase retrasada de activación de red (la backpropagación).
	<b>File</b>	Lee una variedad de tipos del archivo y proporciona los datos como entrada a la red.	Para el aporte de la red y datos deseados de un archivo.
	<b>hresholdTransmitter</b>	El transmisor Thresholded.	Para lo controlante el componente basó en los valores de otro.
	<b>BarChart</b>	Exhibe los datos en una forma de la carta de barra.	Los despliegues que los datos vedan hacen un gráfico de estilo
	<b>DataGraph</b>	Generador de gráficos.	Exhibe datos versus el tiempo.
	<b>MatrixViewer</b>	Exhibe datos instantáneos como matriz numérica	Exhibe valores numéricos en el instante actual con el tiempo.
	<b>DataWriter</b>	Exhibe datos para ingreso de pruebas numéricas	Exhibe valores numéricos a través del tiempo. También tiene previsto el ahorro de datos para un archivo.

• Tabla N° 01 Principales Iconos de NeruoSolutions 5.0

## B. MATRIZ DE CONSISTENCIA

TITULO	PROBLEMA	OBJETIVOS	HIPOTESIS	VARIABLES	INDICADOR	DISEÑO	POBLACION Y MUESTRA
<p><b>Modelo de Red Neuronal Recurrente en la predicción de las variables estratégicas de marketing y venta de la industria de panificación</b></p>	<p>¿En qué medida, el Modelo de Red Neuronal Recurrente, mejora la precisión de la predicción del comportamiento futuro de las variables estratégicas de Marketing y Ventas de la industria de panificación?</p>	<p>Establecer el grado de precisión del Modelo de Red Neuronal Recurrente en la predicción del comportamiento futuro de las variables estratégicas de Marketing y Ventas de la industria de panificación.</p>	<p>El Modelo de Redes Neuronales Artificiales Recurrentes tiene mayor precisión en la Predicción frente a las técnicas estadísticas aplicadas a las variables estratégicas de Marketing y Ventas de la Industria de Panificación.</p>	<p>Variable Dependiente</p> <p>Precisión en la Predicción de las Variables de Marketing y Ventas</p> <p>Variables Independientes</p> <p>Modelo estadístico de regresión lineal.</p> <p>Modelo de series de tiempo</p> <p>Modelo de RNA Recurrente</p>	<p><math>\alpha</math> = Nivel de significancia</p> <p>Error cuadrático medio (NMSE).</p> <p>Menor Desviación Media (MAD)</p> <p>Error cuadrático medio (NMSE).</p> <p>% Error cuadrático medio (NMSE).</p> <p>Desviación Estándar Media (MSE )</p>	<p>Metodología de Investigación</p> <p>a. Análisis y Selección de las variables críticas de éxito de Marketing y Ventas.</p> <p>b. Diseño del Modelo de Red Neuronal Recurrente asociado al área de Marketing y Ventas</p> <p>c. Validación del Modelo Red Neuronal Recurrente asociado al área de Marketing y Ventas</p> <p>d. Predicción del comportamiento de las variables de marketing y ventas utilizando las técnicas estadísticas.</p> <p>e. Comparar la precisión del pronóstico del modelo de red neuronal recurrente con los modelos estadísticos.</p> <p>Tipo de Investigación</p> <p>La presente investigación es aplicada, descriptiva, explicativa y experimental.</p>	<p>La población está conformada por las ventas mensuales de una línea de producto. Las ventas analizadas corresponden desde Dic. 2005 a Dic 2009.</p> <p>La muestra para el estudio es intencional. Referencia bibliográfica Hernández Sampieri (2003).</p>