

**UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS**

**FACULTAD DE INGENIERIA DE SISTEMAS E INFORMÁTICA**

**E.A.P. DE INGENIERIA DE SISTEMAS**

**Sistema de pronóstico de la demanda de productos  
farmacéuticos basado en redes neuronales**

**TESIS**

para optar el título profesional de Ingeniero de Sistemas

**AUTORES**

**Eybi Gil Zavaleta**

**Enith Rodríguez Collas**

**ASESOR**

**David Mauricio**

**Lima – Perú**

**2010**

**Eybi Gil Zavaleta    Enith Rodríguez Collas**

**Sistema de Pronóstico de la Demanda de Productos  
Farmacéuticos Basado en Redes Neuronales**

“Tesis presentada a la Universidad Nacional  
Mayor de San Marcos (Lima – Perú), para  
obtener el Título de Ingeniero de Sistemas”

**LIMA – PERÚ**

**Agosto, 2010**

© Eybi Gil Zavaleta y Enith Rodríguez Collas, 2010  
Todos los derechos reservados.

Este trabajo está dedicado a nuestras familias, que siempre han mantenido la esperanza en nosotras y han confiado plenamente en nuestra capacidad de superación.

## **AGRADECIMIENTOS**

Al profesor David Mauricio por su orientación y dedicación brindada para que este trabajo cumpla con los objetivos trazados.

A nuestras familias por apoyarnos a lo largo de la carrera y, más aún, a lo largo del trabajo que representa la culminación de la misma.

A todas aquellas personas que indirectamente nos ayudaron a cumplir este trabajo y que constituyen un invaluable apoyo.

Y por encima de todo, damos gracias a Dios.

# ÍNDICE

Lista de figuras	xii
Lista de tablas	xvi

## CAPÍTULO 1: INTRODUCCIÓN

1.1. Antecedentes.....	1
1.2. El problema.....	2
1.3. Objetivos.....	2
1.3.1.Objetivo principal.....	2
1.3.2.Objetivos específicos.....	2
1.4. Justificación.....	3
1.5. Alcances y limitaciones.....	4
1.6. Propuesta.....	4
1.7. Organización de la tesis.....	6

## CAPÍTULO 2: PRONÓSTICO DE LA DEMANDA

2.1. Demanda.....	7
2.1.1. Definición.....	7
2.1.2. Elementos de la demanda.....	8
2.2. Pronóstico.....	9
2.2.1. Definición.....	9
2.2.2. Enfoques de pronóstico.....	9
2.2.3. Proceso de pronóstico de la demanda.....	10

## CAPÍTULO 3: REDES NEURONALES

3.1. Definición .....	12
3.2. Elementos básicos.....	12
3.3. Clasificación de las RNAs.....	13
3.4. Parámetros de la red.....	14
3.5. Ventajas.....	15
3.6. Herramienta de aplicación.....	16

## CAPÍTULO 4: ESTADO DEL ARTE

4.1. Taxonomía.....	17
4.1.1. Según el horizonte definido.....	17
4.1.2. Según el tipo de pronóstico.....	17
4.2. Aplicaciones.....	18
4.2.1. Predicción del consumo de fármacos a partir de RNAs.....	19
4.2.2. Sistema híbrido para pronosticar demandas de productos de telecomunicaciones .....	19
4.2.3. Un modelo Spline para el pronóstico de la demanda de la energía.....	20
4.3. Métodos de pronóstico.....	20
4.3.1. Modelos cuantitativos.....	21
4.3.1.1. Análisis de series de tiempo.....	21
4.3.1.2. Promedio de movimiento simple.....	22
4.3.1.3. Ajuste exponencial.....	22
4.3.1.4. Análisis de regresión lineal.....	23
4.3.2. Modelos cualitativos.....	23
4.4. Redes neuronales artificiales.....	24
4.4.1. Perceptrón multicapa.....	24
4.4.2. Red Elman - Jordan.....	25
4.4.3. Red de base radial.....	26
4.5. Casos de Estudio.....	27
4.5.1. Sistema Demand Forecasting.....	27
4.5.2. Sistemas de pronóstico de la demanda en Whirlpool Argentina.....	28
4.5.3. Predicción de la demanda eléctrica horaria mediante RNAs.....	29
4.5.4. Pronóstico del déficit de viviendas en el estado de Mrida con RNAs....	33
4.6. Normas legales.....	38
4.7. Evaluación comparativa de métodos de pronóstico.....	39
4.7.1. Criterios de comparación.....	41
4.7.2. Relación de valores y puntaje por criterio.....	42
4.7.3. Cuadro comparativo.....	45
4.8. Evaluación comparativa de redes neuronales para pronóstico.....	48
4.8.1. Criterios de comparación.....	48
4.8.2. Relación de valores y puntaje por criterio.....	49
4.8.3. Cuadro comparativo.....	50

## CAPÍTULO 5: DISEÑO DE LA RNA PARA EL PRONÓSTICO

5.1. Flujo de procesos.....	52
5.2. Construcción de la red neuronal base.....	53
5.2.1. Descripción de los productos.....	53
5.2.2. Definición de las variables de entrada.....	53
5.2.3. Definición de las variables de salida.....	55
5.2.4. Topología de la red.....	55

## CAPÍTULO 6: SISTEMA DE PRONÓSTICO

6.1. Configuración.....	57
6.1.1. Requerimientos de Hardware y Software para pruebas.....	57
6.1.2. Requerimientos mínimos de Hardware y Software.....	57
6.2. Instancias de pruebas.....	57
6.2.1. Instancias de pruebas para el entrenamiento.....	59
6.2.2. Instancias de pruebas para la validación.....	61
6.3. Normalización de los Datos.....	61
6.4. Fase de entrenamiento.....	63
6.4.1. Proceso de entrenamiento de la RN del producto DF.....	63
6.4.1.1. Configuraciones de las redes.....	63
6.4.1.1.1. Configuración 1.....	63
6.4.1.1.2. Configuración 2.....	65
6.4.1.1.3. Configuración 3.....	67
6.4.1.1.4. Configuración 4.....	69
6.4.1.1.5. Configuración 5.....	71
6.4.1.1.6. Configuración 6.....	73
6.4.1.1.7. Configuración 7.....	75
6.4.1.1.8. Configuración 8.....	77
6.4.1.2. Resumen del proceso de entrenamiento de la RN del producto DF..	79
6.4.1.3. Configuración escogida para el producto DF.....	80
6.4.2. Proceso de entrenamiento de la RN del producto RG.....	80
6.4.3. Proceso de entrenamiento de la RN del producto CH.....	81
6.5. Fase de validación.....	81
6.5.1. Validación de las redes del producto DF.....	81
6.5.1.1. Procedimiento en MatLab.....	81
6.5.1.2. Tasa de error.....	82
6.5.2. Validación de las redes del producto RG.....	83
6.5.3. Validación de las redes del producto CH.....	83



6.6. Sistema de pronóstico.....	84
6.6.1. Conexión JAVA- MATLAB.....	84
6.6.2. Interfaz de usuario.....	85
6.6.2.1. Usuario operador.....	86
6.6.2.2. Usuario administrador.....	87
6.6.3. Prueba del sistema.....	90
6.6.4. Rendimiento de la red neuro nal frente al experto.....	91
<b>CAPÍTULO 7: CONCLUSIONES Y TRABAJOS FUTUROS</b>	
7.1. Conclusiones.....	95
7.2. Trabajos futuros.....	96
REFERENCIAS BIBLIOGRÁFICAS.....	97
ANEXO A Ley general de Salud .....	102
ANEXO B Herramienta MATLAB .....	106
ANEXO C Datos históricos de los productos RG y CH.....	111
ANEXO D Entrenamiento y validación de la RNA.....	120
ANEXO E Selección de las variables de entrada.....	124

## Lista de figuras

Figura 1.1. Cuadro comparativo entre el valor real y el valor proyectado de la demanda de agua	4
Figura 1.2. Esquema del desarrollo de la solución planteada del problema	5
Figura 2.1. Esquema del proceso de la demanda	10
Figura 3.1. Representación de una red neuronal artificial	13
Figura 3.2. Taxonomía de las redes neuronales según ciertos parámetros	13
Figura 4.1. Perceptrón multicapa	25
Figura 4.2. Arquitectura de la red de Elman	26
Figura 4.3. Red de base radial	26
Figura 4.4. Modelo del proceso de pronóstico y planificación	28
Figura 4.5. Arquitectura de la red PMC	29
Figura 4.6. Curva de carga observada y la ajustada por el modelo en el entrenamiento demanda observada y ajustada	31
Figura 4.7. Representación de la curva de carga observada y la ajustada por el modelo con datos desconocidos.	32
Figura 4.8. Representación de los modelos de red RBF	37
Figura 4.9. Comportamiento de patrones de datos en el tiempo	41
Figura 5.1. Flujo de procesos propuesto para la resolución del problema basado en el esquema del proceso de la demanda [Cox+02]	52
Figura 5.2. Esquema de la red a construir	55
Figura 5.3. Arquitectura de la red neuronal para cada	56
Figura 6.1. Configuración de la red PRONOSTICADOR_1	63
Figura 6.2. Esquema de la red neuronal PRONOSTICADOR_1	64
Figura 6.3. Configuración de los parámetros solicitados por la red PRONOSTICADOR_1	64

Figura 6.4. Configuración de los pesos de la red PRONOSTICADOR_1	64
Figura 6.5. Imagen del entrenamiento realizado por la red PRONOSTICADOR_1	65
Figura 6.6. Configuración de la red PRONOSTICADOR_2	65
Figura 6.7. Esquema de la red neuronal PRONOSTICADOR_2	66
Figura 6.8. Configuración de los parámetros solicitados por la red PRONOSTICADOR_2	66
Figura 6.9. Configuración de los pesos de la red PRONOSTICADOR_2	66
Figura 6.10. Imagen del entrenamiento realizado por la red PRONOSTICADOR_2	67
Figura 6.11. Configuración de la red PRONOSTICADOR_3	67
Figura 6.12. Esquema de la red neuronal PRONOSTICADOR_3	68
Figura 6.13. Configuración de los parámetros solicitados por la red PRONOSTICADOR_3	68
Figura 6.14. Configuración de los pesos de la red PRONOSTICADOR_3	68
Figura 6.15. Imagen del entrenamiento realizado por la red PRONOSTICADOR_3	69
Figura 6.16. Configuración de la red PRONOSTICADOR_4	69
Figura 6.17. Esquema de la red neuronal PRONOSTICADOR_4	70
Figura 6.18. Configuración de los parámetros solicitados por la red PRONOSTICADOR_4	70
Figura 6.19. Configuración de los pesos de la red PRONOSTICADOR_4	70
Figura.6.20. Imagen del entrenamiento realizado por la red PRONOSTICADOR_4	71
Figura 6.21. Configuración de la red PRONOSTICADOR_5	71
Figura 6.22. Esquema de la red neuronal PRONOSTICADOR_5	72
Figura 6.23. Configuración de los parámetros solicitados por la red PRONOSTICADOR_5	72
Figura 6.24. Configuración de los pesos de la red PRONOSTICADOR_5	72
Figura 6.25. Imagen del entrenamiento realizado por la red PRONOSTICADOR_5	73
Figura 6.26. Configuración de la red PRONOSTICADOR_6	73
Figura 6.27. Esquema de la red neuronal PRONOSTICADOR_6	74
Figura 6.28. Configuración de los parámetros solicitados por la red PRONOSTICADOR_6	74
Figura 6.29. Configuración de los pesos de la red PRONOSTICADOR_6	74

Figura 6.30. Imagen del entrenamiento realizado por la red PRONOSTICADOR_6	75
Figura 6.31. Configuración de la red PRONOSTICADOR_7	75
Figura 6.32. Esquema de la red neuronal PRONOSTICADOR_7	76
Figura 6.33. Configuración de los parámetros solicitados por la red PRONOSTICADOR_7	76
Figura 6.34. Configuración de los pesos de la red PRONOSTICADOR_7	76
Figura 6.35. Imagen del entrenamiento realizado por la red PRONOSTICADOR_7	77
Figura 6.36. Configuración de la red PRONOSTICADOR_8	77
Figura 6.37. Esquema de la red neuronal PRONOSTICADOR_8	78
Figura 6.38. Configuración de los parámetros solicitados por la red PRONOSTICADOR_8	78
Figura 6.39. Configuración de los pesos de la red PRONOSTICADOR_8	78
Figura 6.40. Imagen del entrenamiento realizado por la red PRONOSTICADOR_8	79
Figura 6.41. Vector se salida realizado por la red PRONOSTICADOR_6	82
Figura 6.42. Vector de error realizado por la red PRONOSTICADOR_6	82
Figura 6.43. Acceso al sistema de pronóstico.	86
Figura 6.44. Interfaz de pronóstico – Usuario operador	86
Figura 6.45. Interfaz de pronóstico – Usuario administrador	87
Figura 6.46. Configuración de los valores máximos del producto elegido	88
Figura 6.47. Creación y entrenamiento de una RNA	88
Figura 6.48. Validación de una RNA	89
Figura 6.49. Gráfica de la validación de la red neuronal	89
Figura 6.50. Prueba del sistemas	90

## Lista de tablas

Tabla 2.1. Descripción de los métodos más utilizados para pronósticos	9
Tabla 4.1. Descripción de las variables de entrada	30
Tabla 4.2. Valores óptimos de los parámetros del entrenamiento.	31
Tabla 4.3. Valores de entrenamiento	32
Tabla 4.4. Resultados de la predicción.	33
Tabla 4.5. Comparación con otros modelos.	33
Tabla 4.6. Variables de entrada	34
Tabla 4.7. Variables de salida	35
Tabla 4.8. Variables definidas para el modelo	36
Tabla 4.9. Características de la red	37
Tabla 4.10. Tasa de aprendizaje para cada período	37
Tabla 4.11. Error teórico de cada época	37
Tabla 4.12. Parámetros de la red	38
Tabla 4.13. Entrenamiento de la red	38
Tabla 4.14. Valores y puntaje por criterio de comparación de tipos de pronóstico	44
Tabla 4.15. Comparación de criterios con asignación de valores	46
Tabla 4.16. Comparación de criterios con asignación de puntajes	47
Tabla 4.17. Valores y puntaje por criterios de comparación de RNAs	50
Tabla 4.18. Comparación de criterios con asignación de valores	51
Tabla 4.19. Comparación de criterios con asignación de puntajes	51
Tabla 5.1. Descripción de productos a pronosticar	53
Tabla 5.2. Definición de variables de entrada del modelo	54
Tabla 6.1. Datos totales para el entrenamiento y validación	58

Tabla 6.2. Datos para la fase de entrenamiento	59
Tabla 6.3. Datos para la fase de validación	60
Tabla 6.4. Datos normalizados para la fase de entrenamiento	62
Tabla 6.5. Datos normalizados para la fase de validación	62
Tabla.6.6. Resumen del proceso de entrenamiento de la RN del producto DF	79
Tabla.6.7. Resumen del proceso de entrenamiento de la RN del producto RG	80
Tabla.6.8. Resumen del proceso de entrenamiento de la RN del producto CH	81
Tabla.6.9. Resumen del proceso de validación - Producto DF	83
Tabla.6.10. Resumen del proceso de validación - Producto RG	83
Tabla.6.11. Resumen del proceso de validación - Producto CH	83
Tabla 6.12. Cuadro comparativo (cantidades del experto vs. cantidades de la DF)	92
Tabla 6.13. Cuadro comparativo (cantidades del experto vs. cantidades de la RG)	93
Tabla 6.14. Cuadro comparativo (cantidades del experto vs. cantidades de la CH)	94

# **Sistema de Pronóstico de la Demanda de Productos Farmacéuticos Basado en Redes Neuronales**

## **RESUMEN**

La supervivencia en los negocios altamente competitivos de hoy requiere una visión precisa de la demanda para poner en marcha los planes de producción, inventario, distribución y compra dentro de las empresas; el sector farmacéutico no es la excepción, pues los efectos de las temporadas, promociones, cambios de precios, publicidad, productos con bajo o alto nivel de movimiento y datos atípicos en general afectan en la determinación de la misma. En este contexto, pronosticar por arriba de la demanda tiene entre sus consecuencias el excesivo inventario de fármacos, obsolescencia o caducidad, y por otro lado, pronosticar por debajo de la demanda tiene como consecuencia la pérdida de las ventas y un posible incremento en los costos. Por lo mencionado, el tema se centra en el desarrollo de un sistema que usa las técnicas de redes neuronales artificiales para el pronóstico de la demanda de productos.

En este trabajo se propone el uso de una red neuronal (Perceptrón multicapa) para el pronóstico de la demanda de productos farmacéuticos, la cual realizará su fase de aprendizaje con el algoritmo backpropagation que brinda una tasa de error de 3.57% en el mejor caso encontrado; su implementación se desarrollará bajo la tecnología de MATLAB para la construcción de la red neuronal y del lenguaje JAVA para el diseño de la interfaz gráfica de usuario.

Palabras clave: Pronóstico de la demanda, Backpropagation, sector farmacéutico.

# Forecast System Demand for Pharmaceuticals Based on Neural Networks

## ABSTRACT

The survival in the highly competitive business of today needs a precise vision of the demand to put in march the plans of production, inventory, distribution and buy inside the companies; the pharmaceutical sector is not the exception, so he effects of the seasons, promotions, changes of prices, trends, products with under or high level of movement and atypical information affects in the determination of the same one. In this context, to predict overhead of the demand it as between his consequences the overstock of medicaments, obsolescence or caducity, and on the other hand, to predict below the demand has as consequence the loss of sales and the possible increase in the costs. For the mentioned, the topic centres on the development of a system that uses the technologies of Artificial Neural Networks and of the diffuse logic for the forecast of the demand of products.

This paper proposes the use of a neural network (multilayer perceptron) for the prediction of demand for pharmaceuticals, which will hold its learning phase with the backpropagation algorithm that provides an error rate of 3.57%; its implementation will under MATLAB technology for building the neural network and the JAVA language for the design of the graphical user interface.

Keywords: Demand forecasting, Backpropagation, Pharmaceutical sector.



# *Capítulo 1*

## *Introducción*

### **1.1. Antecedentes**

La planeación en toda industria es una necesidad, un punto vital. Se puede decir incluso que el objetivo importante de la planeación es tratar de prever lo que sucederá en el futuro a base de una recopilación de hechos o sucesos acaecidos con anterioridad.

Los métodos estadísticos convencionales usan en general determinados parámetros o datos asociados a períodos de tiempo cuya relación con la previsión de demanda es complicada; la realidad es que muchos de los que toman decisiones en el campo de la previsión de demanda lo hacen basándose en su instinto y experiencia. La realidad también nos dice que la demanda se establece como un requisito primordial que debe soportar el plan financiero o plan de ventas con lo que, la mayor parte de las veces, el proceso de planificación de la demanda está fuertemente condicionado por elementos que, en un principio, tiene que ver con el mercado y los clientes [Serna03].

El método usual de planeación al interior de las empresas inicia con un proceso de pronóstico de la demanda, pronóstico bien sea elaborado con un simple crecimiento sobre resultados anteriores o mediante herramientas tecnológicas que permiten efectuar innumerables cálculos para tratar de que el pronóstico sea lo más cercano a la realidad. Muchas de estas herramientas son extremadamente costosas y, peor aún, no son muchas las personas que pueden efectuar un pronóstico seguro a partir de los resultados de las mismas.

Inicialmente, los pronósticos en las empresas se elaboraban por expertos que realizaban el análisis de un simple crecimiento sobre resultados anteriores mostrados en reportes históricos de ventas (instinto y experiencia). Luego, se pasó a utilizar métodos estadísticos convencionales (lineales) tales como los modelos básicos de regresión, el Análisis de Series de Tiempo, etc.; para hacer uso de este tipo de herramientas es común requerir información cuantitativa del comportamiento de la demanda a través del tiempo, es decir, una serie de tiempo, siendo el Análisis de Series de Tiempo la técnica estadística más utilizada para estimar su comportamiento. Estos métodos estadísticos convencionales usan en general determinados parámetros o datos asociados a períodos de tiempo cuya relación con la previsión de demanda es complicada; la realidad es que muchos de los que toman decisiones en el campo de la previsión de demanda lo hacen basándose en sus instintos y experiencias, las cuales son utilizadas para valorar el impacto de campañas promocionales, de introducción de nuevos productos u otros. Por muchos años, este tipo de análisis ha estado dominado por la utilización de métodos estadísticos lineales que se pueden implementar de manera conveniente; sin embargo, la existencia de relaciones no lineales entre los datos muchas veces limitaron la aplicación de estos modelos. Por este motivo, se introdujo la idea de utilizar (RNA) en pronóstico de Series de Tiempo que fue aplicada por primera vez en 1964, cuando se utilizó una Red Neuronal Artificial lineal para

el pronóstico del clima [Nojek+02]. En el año 2004 se llevó a cabo un trabajo similar de predicción en la sección de estudios de Postgrado de la Unidad Profesional Interdisciplinaria de Ingeniería y Ciencias Sociales y Administrativas (México), el cual consistía en una tesis de pronóstico de ventas de un laboratorio farmacéutico para sus productos líderes, en esta ocasión la metodología que se desarrolló se basó en un enfoque estadístico.

Actualmente, las redes neuronales artificiales son una de las técnicas más usadas para la resolución de pronósticos de este tipo debido a sus óptimos resultados y su fácil metodología de resolución, es así que se pueden encontrar muchos trabajos sobre este tema.

## **1.2. El problema**

El problema que se pretende resolver es la predicción inexacta de la cantidad demandada de ciertos productos farmacéuticos adquiridos por la empresa respecto a la demanda real que genera inventarios en exceso o en falta, lo cual rebaja los niveles de servicio a los compradores, siendo este un factor influyente para el éxito de la empresa.

La dificultad del problema se encuentra en el cálculo del pronóstico dentro de un ambiente imprevisible que proyecta una tasa de error relativamente alta ante los resultados obtenidos en la realidad, esto debido al uso de herramientas de pronóstico informales que realizan cálculos manuales en base a datos históricos o simplemente recurren a la consulta de un experto, métodos que no contemplan ciertas eventualidades acaecidas que repercuten en la demanda de dichos productos farmacéuticos, tales como promociones, publicidades, temporadas, etc. [Edelman02].

## **1.3. Objetivos**

### **1.3.1. Objetivo principal**

Diseñar e implementar un sistema de pronóstico de la demanda de productos farmacéuticos más adecuado mediante el uso de la técnica de Redes Neuronales Artificiales para la obtención de la menor tasa de error entre la demanda real y la demanda pronosticada.

### **1.3.2. Objetivos específicos**

- Investigar e identificar variables que puedan ser cuantificadas y analizar la intervención de dichas variables con la elaboración de los pronósticos.
- Buscar y analizar las metodologías y modelos que existen para la realización de pronósticos de la demanda.
- Averiguar el proceso de pronóstico actual de demanda de productos farmacéuticos en las distribuidoras, droguerías y laboratorios.

- Evaluar y seleccionar el método más adecuado para el pronóstico de la demanda de productos farmacéuticos.
- Obtener una base de datos histórica de la demanda de productos farmacéuticos, que será usada para entrenamiento.
- Elaborar y desarrollar la arquitectura de la red neuronal más apropiada para el pronóstico de la demanda de productos farmacéuticos.
- Revisar los algoritmos existentes para el entrenamiento de la red neuronal y seleccionar el algoritmo adecuado para su aprendizaje.
- Diseñar un software de predicción basado en la técnica de redes neuronales e implementarlo a partir de las tecnologías empleadas en la actualidad.

## **1.4. Justificación**

El problema del pronóstico de la demanda se presenta hoy en día en casi todas las aplicaciones de las empresas, ya sea dedicada a bienes (productos) o servicios; así mismo, es un punto que no se puede obviar en la planificación de la cadena de suministro o en la administración de demanda. Cuando una empresa pueda optar por trabajar de acuerdo a la demanda y no a pronósticos, se puede ufanar de tener un negocio completamente integrado y, por ende, se elimina la necesidad de "adivinar" o suponer la demanda para la elaboración del pronóstico. Al trabajar con predicciones, la empresa tendrá una visión de lo que necesitará en el futuro para satisfacer la demanda, además tendrá información de la cantidad y duración de ésta. Con estas predicciones, la empresa es capaz de desarrollar pronósticos de recursos (tiempo, equipos, fuerza de trabajo, compra de partes y materiales) cada vez más precisos.

Actualmente, el ambiente competitivo empresarial ha motivado el reconocimiento de la función de planeación como una necesidad indispensable en el proceso de administración de negocios. Un estudio hecho por el Institute of Business Forecasting titulado "Why Forecasting?" menciona que: "hoy en día es ineludible un proceso más formal de elaborar los pronósticos sin importar en qué tipo de negocio y/o industria se localice la empresa o qué función realiza. Siempre hay una necesidad de estimar el futuro sobre la cual construir un plan" [Morwitz+00]. Lo indicado es incuestionable, así como señalar que los responsables directos de la planeación requieren de información cabal para realizar pronósticos más exactos, ya que esta tarea resulta laboriosa y difícil, pues se deben considerar actividades planeadas como promociones, cambios de precios o, incluso, eventos extraordinarios en la historia reciente que puedan desviar fuertemente las estimaciones. Dejar esto a la memoria causará pronósticos menos precisos.

Por otro lado, en el año 2002, el mercado farmacéutico total estaba estimado en US\$ 528 millones (sector privado 79%, sector público 21%) y las compras mensuales tanto del sector público como privado eran muy variables, lo que originaba realizar complejos análisis para la planificación.

Se necesita de un buen pronóstico para optimizar la planeación de ventas, ya que con esto se logrará un mejor nivel de servicio, un menor costo de capital y una máxima rentabilidad de la empresa.

Podemos apreciar en la Figura 1.1 que el margen de error en el que incurren las empresas debido al uso de técnicas no apropiadas respecto a la demanda del agua es relativamente alta.

Volumen almacenado al 15.05.2005	Volumen al 15.07.2005		% Error
	Proyectado	Real	
243.48	229.1	205.38	11.5

Figura 1.1. Cuadro comparativo entre el valor real y el valor proyectado de la demanda de agua [Proyección de Sedapal, 2005]

## 1.5. Alcances y limitaciones

Se realizará el estudio acerca de la demanda del sector farmacéutico en el Perú, específicamente para una empresa distribuidora establecida en la ciudad de Lima, y cómo influyen las variables dependientes en los patrones de demanda de los productos farmacéuticos. El pronóstico se llevará a cabo para la línea de productos farmacéuticos OTC (sin prescripción médica), que son los más volátiles con respecto a su demanda.

La empresa en la que se desarrollarán las pruebas la denominaremos FARMOTC. Los casos de estudio, en primera instancia, se realizarán en la misma empresa, luego se buscarán opciones de aceptación de otros laboratorios para poder llevar a cabo más casos de estudio con el mismo sistema y, de esta manera, realizar las comparaciones debidas y los porcentajes de resultados favorables que se desean obtener.

La plataforma a utilizar contempla la TECNOLOGÍA JAVA, IDE NetBeans 6.5 que es la última versión actual para la implementación de la capa de interfaz de usuario, el lenguaje de programación MATLAB 7.3 para la implementación de la red neuronal de la capa de proceso.

## 1.6. Propuesta

La propuesta que se plantea en el presente trabajo es encontrar una red neuronal artificial adecuada para pronosticar la demanda de productos farmacéuticos (que muestra un patrón no lineal) haciendo uso de un algoritmo de aprendizaje conveniente para la red a implementar. Básicamente se comprende el desarrollo de un sistema de predicción que use la técnica de redes neuronales artificiales para la capa de proceso, integrado con un lenguaje que posee interfaz gráfica de usuario para la capa del cliente. Este desarrollo implicará demostrar:

- Aplicabilidad de los algoritmos de aprendizaje desarrollados para redes neuronales para aproximar una función no lineal correspondiente a la función pronóstico.
- Posibilidad de promover el uso de técnicas de Redes Neuronales ya implementadas en la obtención de resultados de trascendencia empresarial, uno de los cuales es el pronóstico de demanda.

En el siguiente esquema, Figura 1.2, se muestra un esquema genérico el desarrollo de la propuesta planteada.

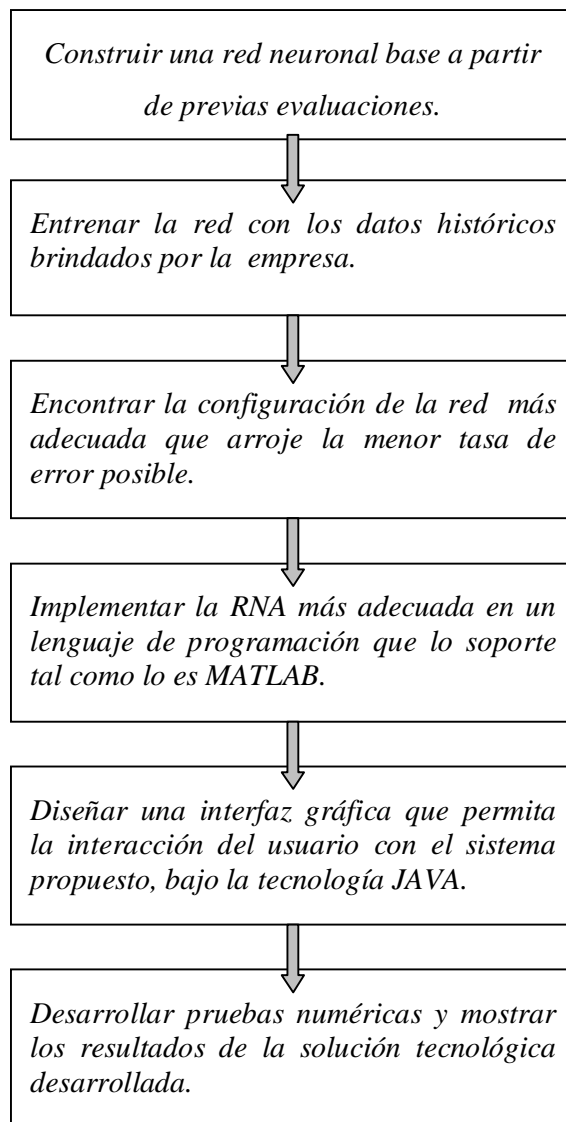


Figura 1.2. Esquema del desarrollo de la solución planteada del problema

## **1.7. Organización de la tesis**

La tesis está organizada en siete capítulos, los cuales se mencionan a continuación:

En el capítulo 2, se realiza el estudio del marco teórico de la demanda, enfatizando la literatura sobre el enfoque del problema que es el pronóstico de la demanda, dando conceptos de pronóstico, demanda, tipos, y también sobre la gestión de inventarios como un punto extra para la mayor comprensión sobre el tema.

En el capítulo 3, se realiza el estudio del marco teórico de las redes neuronales artificiales, así como el funcionamiento, arquitectura y aplicaciones que se pueden llevar a cabo con esta técnica.

En el capítulo 4, se realiza el estudio del estado del arte del pronóstico de la demanda de productos en general, que consta de la clasificación del problema, los métodos, modelos, algoritmos y aplicaciones existentes para su solución.

En el capítulo 5, se desarrolla el aporte teórico de la presente tesis, que consta de la elaboración del modelo de red neuronal más adecuada para la obtención de buenos resultados para los productos que han sido previamente seleccionados.

En el capítulo 6, se desarrolla el aporte práctico de la presente tesis, que consta del desarrollo del software predictor. Como primer punto se explican los requerimientos de hardware y software para su implementación, la explicación sobre las instancias de prueba desarrolladas con la herramienta Neural Network que brinda el MATLAB, la elección de la red neuronal más adecuada y su integración con el IDE NetBeans de Java para el enmascaramiento respectivo y, como paso final, se muestran las pruebas realizadas con un producto escogido.

Por último, en el capítulo 7, se mencionan las conclusiones de la tesis y los futuros trabajos que se puedan desarrollar.

# Capítulo 2

## *Pronóstico de la demanda*

La predicción de eventos futuros siempre ha fascinado al género humano y se puede decir que las técnicas de predicción existen desde que éste existe. Sin embargo, con el paso del tiempo, estas técnicas se han ido sofisticando y se han aplicado en distintas áreas, con fines científicos y económicos, como en la predicción del tiempo, en la predicción del cambio entre monedas, productos en general, etc. Por lo cual, para el tomador de decisiones es necesario conocer el comportamiento de la demanda de los productos en general a través del tiempo, es por eso que es necesario el análisis de la demanda en el tiempo, debido a que actualmente hay situaciones en las cuales se toma decisiones basadas en la experiencia.

### **2.1. Demanda**

#### **2.1.1. Definición**

Según el padre del marketing, Philip Kotler, la demanda es el deseo que se tiene de un determinado producto pero que está respaldado por una capacidad de pago. Se refiere a las cantidades de un producto que los consumidores están dispuestos a comprar a los posibles precios del mercado. Aclarando, la demanda es la cantidad de bienes o servicios que el comprador o consumidor está dispuesto a adquirir a un precio dado y en un lugar establecido, con cuyo uso pueda satisfacer parcial o totalmente sus necesidades particulares o pueda tener acceso a su utilidad intrínseca [Armstrong+06].

La administración de la demanda implica reconocer fuentes de demanda para los bienes y servicios de una empresa, predecir la demanda y determinar la manera como la empresa satisfará esa demanda. Las predicciones de demanda pronostican la cantidad y la duración de los bienes y servicio de una empresa.

Las instalaciones no utilizadas, productos excedentes que quedan en el inventario, etc., significan costos fijos excesivos que reducen la utilidad a menos de lo que es posible. Por lo tanto, existen varias tácticas para igualar la capacidad con la demanda.

Los cambios internos incluyen el ajuste del proceso para un cierto volumen a través de:

- Ajuste de la cantidad de productos
- Mejoramiento de los métodos para aumentar la salida
- El rediseño del producto para acilitar más rendimiento
- Cambios en el personal

El objetivo de la demanda es medir cuáles son las fuerzas que afectan los requerimientos del mercado con respecto a un bien o servicio y determinar la posibilidad de participación del producto en la satisfacción de dicha demanda. La demanda es la función de factores tales como la necesidad del bien, su precio, el nivel de ingreso de la población, etc.

### 2.1.2. Elementos de la demanda

A continuación, se describen un conjunto de partes que conforman la demanda [Mentzer+98]:

- **Cantidad de bienes o servicios.** Se refiere a un cierto número de unidades que los compradores estarían dispuestos a comprar o que ya han sido adquiridas.
- **Compradores o consumidores.** Son las personas, empresas u organizaciones que adquieren determinados productos para satisfacer sus necesidades o deseos.
- **Necesidades y deseos.** La necesidad humana es el estado en el que se siente la privación de algunos factores básicos (alimento, vestido, abrigo, seguridad, sentido de pertenencia, estimación). En cambio, los deseos consisten en anhelar los satisfactores específicos para estas necesidades profundas.
- **Disposición a adquirir el producto o servicio.** Se refiere a la determinación que tiene el individuo, empresa u organización por satisfacer su necesidad o deseo.
- **Capacidad de pago.** Es decir, que el individuo, empresa u organización tiene los medios necesarios para realizar la adquisición.
- **Precio dado.** Es la expresión de valor expresado, por lo general, en términos monetarios, que tienen los bienes y servicios.
- **Lugar establecido.** Es el espacio, físico o virtual (como el Internet), en el que los compradores están dispuestos a realizar la adquisición.

La demanda en economía se define como la cantidad y calidad de bienes y servicios que pueden ser adquiridos a los diferentes precios del mercado por un consumidor (demanda individual) o por el conjunto de consumidores (demanda total o de mercado). La demanda es una función matemática expresada de la siguiente manera [Mentzer+98]:

$$Q = F(P, I, G, N, P_s, P_c)$$

Donde

- Q = es la cantidad demandada del bien o servicio.
- P = precio del bien o servicio.
- I = ingreso del consumidor.
- G = gustos y preferencias.
- N = número de consumidores.
- P<sub>s</sub> = precio de bienes sustitutos.
- P<sub>c</sub> = precio de bienes complementarios.



## 2.2. Pronóstico

### 2.2.1. Definición

Es un proceso que consiste en utilizar datos pasados para determinar acontecimientos futuros. Los pronósticos a menudo son utilizados para poder predecir la demanda del consumidor de productos o servicios, aunque se pueden predecir una amplia gama de sucesos futuros que pudieran de manera potencial influir en el éxito. Pronosticar es el arte y la ciencia de predecir los eventos futuros, puede involucrar el manejo de datos históricos para proyectarlos al futuro, mediante algún tipo de modelo matemático, puede ser una predicción del futuro subjetiva o intuitiva o bien una combinación de ambas, es decir, un modelo matemático ajustado por el buen juicio de un administrador [Nojek+02].

### 2.2.2. Enfoques de pronóstico

Según [Thompson98] los enfoques de cómo resolver problemas de pronósticos son los siguientes:

- **Pronósticos cuantitativos.** Este tipo maneja una variedad de modelos matemáticos que utilizan datos históricos y/o variables causales para pronosticar la demanda, como los mostrados en la Tabla 2.1.
- **Pronósticos cualitativos.** Este tipo incorpora factores importantes tales como la intuición, emociones, experiencias personales del que toma la decisión, y un sistema de valores para alcanzar un pronóstico. Algunas compañías utilizan el enfoque anterior, pero en la práctica una combinación o mezcla de los dos estilos es generalmente más efectivo.

Enfoque	Tipo de modelo	Descripción
Cualitativos	<b>Modelos cualitativos</b> Datos históricos, Técnica de grupo, Nominal, etc.	Preguntas hechas a un grupo de expertos para recabar opiniones. Hace analogías con el pasado de una manera razonada. Proceso de grupo que permite la participación con votación forzada.
Cuantitativos	<b>Modelos cuantitativos</b> Series de tiempo, Medida o promedio Móvil simple, etc.	Promedia los datos del pasado para predecir el futuro basándose en ese promedio.
	<b>Modelo de suavizado exponencial</b>	Da pesos relativos a los pronósticos anteriores y a la demanda más reciente.
	<b>Modelos cuantitativos causales</b>	Describe una relación funcional entre las variables y cantidad pronosticada.

Tabla 2.1. Descripción de los modelos más utilizados para pronósticos

### 2.2.3 Proceso de pronóstico de la demanda

Dentro del proceso de pronóstico de la demanda existen una serie de pasos comunes que realizan las empresas y que requieren ser administrados correctamente para garantizar una calidad en la ejecución de este proceso [Cox+02]. La Figura 2.1 muestra el esquema común de desarrollo que presenta un pronóstico general.

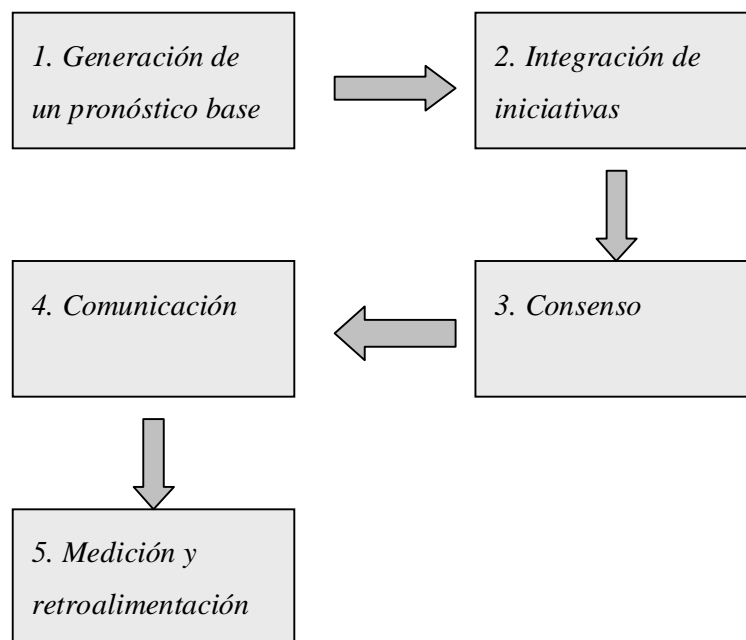


Figura 2.1. Esquema del proceso de la demanda [Cox+02].

A continuación, se detallan cada uno de los procesos mencionados:

**Paso 1. Generación de un pronóstico base.** Inicialmente se requiere contar con una actividad en la cual se determine un pronóstico de partida, denominado pronóstico base. Este tipo de pronóstico es fundamentado en algún método estadístico (series de tiempo es el más utilizado) y se genera a través de una herramienta tecnológica que permita el análisis de grandes volúmenes de información considerando un historial mínimo de 3 años.

**Paso 2. Integración de iniciativas.** El siguiente paso, una vez que se tiene un pronóstico base, es integrar todas aquellas iniciativas tales como: promociones, eventos especiales, impulso estratégico, entre otras que se consideren que provocarán una desviación, a la demanda esperada mayor que la simple tendencia estadística o el factor de crecimiento previamente establecido.

**Paso 3. Consenso.** El proceso de consenso es una reunión realizada cada mes entre las áreas de Mercadotecnia, Ventas y Operaciones en donde se evalúan

desviaciones mayores al  $\pm 15\%$  del pronóstico base de cualquier producto. Con lo anterior se logra definir un pronóstico final de dichos productos, minimizando el riesgo de protección de algunas de las áreas y eliminando las decisiones unilaterales que afectarían el desempeño del proceso.

***Paso 4. Comunicación.*** Una vez concluido el proceso de consenso se determina un pronóstico final, el cual entrará en operación al mes siguiente. Existe un proceso de comunicación formal en la compañía acerca de cuál será el pronóstico de demanda bajo el cual se estará trabajando, y cómo se lleva a cabo el proceso de formalizar el arranque de las estrategias para el resto de planes.

***Paso 5. Medición y retroalimentación.*** Partimos del siguiente principio: “lo que no se mide, no se mejora”, por ello el proceso de planeación de la demanda cuenta con un paso de medición y retroalimentación el cual utiliza algunas técnicas ya conocidas en el mercado.

## Capítulo 3

# Redes neuronales

Las primeras investigaciones sobre redes neuronales datan de principios del siglo XIX, pero fue hasta la década de los cuarenta y cincuenta del siglo XX cuando el estudio de las redes neuronales cobró mayor fuerza gracias al movimiento Conexionista. Este movimiento sostenía la premisa de que el secreto para el aprendizaje y el conocimiento se halla en axiomas o verdades incuestionables y que el conocimiento es independiente de la estructura que maneje los símbolos, y la representación del conocimiento se hace desde el estrato más básico de la inteligencia: el cerebro, especialmente en las neuronas y las múltiples interconexiones entre ellas [Tawfiq+99].

### 3.1. Definición

Las redes neuronales artificiales se constituyen en una técnica de procesamiento masivo y paralelo de la información que emula las características esenciales de la estructura neuronal del cerebro biológico. Las principales diferencias y similitudes entre las redes neuronales biológicas y artificiales [Hilera+95].

### 3.2. Elementos básicos

Una RNA es muy parecida a lo que en matemática discreta se estudia como "grafos". En el caso más simple, cada neurona tiene una serie de variables respecto a sí misma. En todo modelo artificial de neurona se tienen cuatro elementos básicos [Tawfiq+99]:

- *Un sumador*, que se encarga de sumar todas las entradas multiplicadas por las respectivas sinapsis.
- *Un conjunto de conexiones*, pesos o sinapsis que determinan el comportamiento de la neurona. Estas conexiones pueden ser excitadoras (presentan un signo positivo), o inhibitoras (conexiones negativas).
- *Una función de activación*, lineal o no lineal para limitar la amplitud de la salida de la neurona.
- *Un umbral exterior*, que determina el umbral por encima del cual la neurona se activa.

Esquemáticamente, una neurona artificial quedaría representada como en la Figura 3.1.

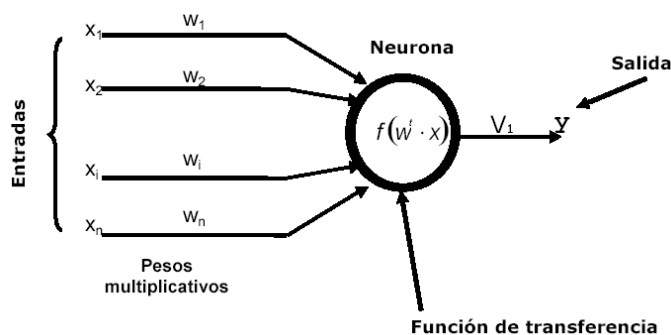


Figura 3.1. Representación de una red neuronal artificial [Tawfiq+99]

### 3.3. Clasificación de las RNAs

En la literatura de las redes neuronales se encuentran muchas formas de clasificación. A continuación, se menciona la taxonomía más acorde con el problema estudiado [Charytoniuk+00].

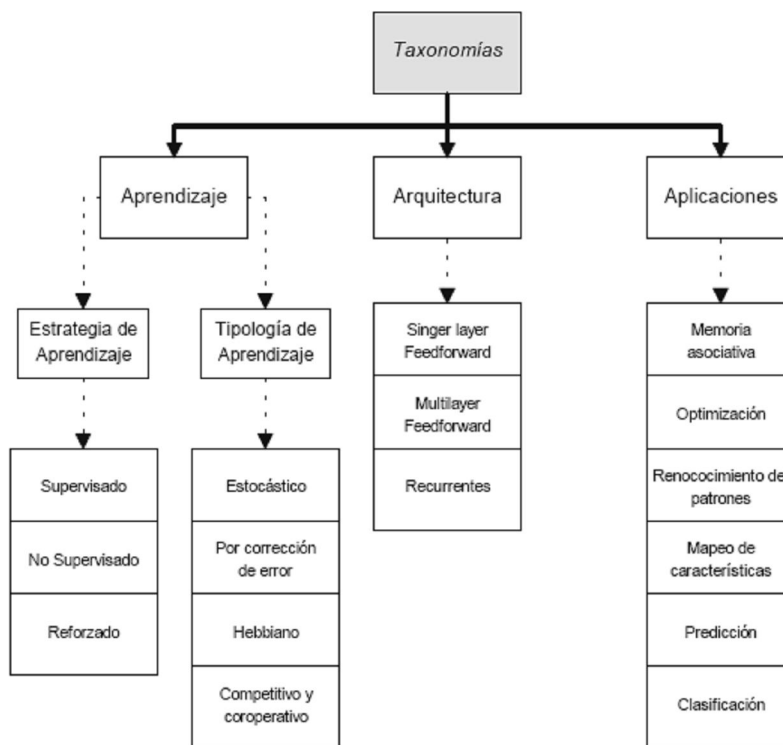


Figura 3.2. Taxonomía de las redes neuronales según ciertos parámetros [Charytoniuk+00]

En la Figura 3.2 se muestra un cuadro con la taxonomía general de las redes neuronales que permite distinguir la ubicación en la que se encuentra el tema de predicción con RNAs. Los elementos básicos comentados se pueden conectar entre sí para dar lugar a las estructuras neuronales o modelos conexionistas que podríamos clasificar de diferentes formas según el criterio usado. [Charytoniuk+00]:

a) **Según su arquitectura**, se clasifican en:

- *Redes Neuronales Monocapas*. Se corresponde con la red neuronal más sencilla ya que se tiene una capa de neuronas que proyectan las entradas a una capa de neuronas de salida donde se realizan diferentes cálculos.
- *Redes Neuronales Multicapa*. Es una generalización de la anterior existiendo un conjunto de capas intermedias entre la entrada y la salida.
- *Redes Neuronales recurrentes*. Esta red viene caracterizada por la existencia de lazos de realimentación. Estos lazos pueden ser entre neuronas de diferentes capas, neuronas de la misma capa o entre una misma neurona.

b) **Según su aprendizaje**, se clasifican en:

- *Aprendizaje Supervisado*. En este rubro se clasifican las redes neuronales que tienen un supervisor en el desarrollo de la red, significa que existe un parámetro de referencia el cual es comparado con las salidas de la red.
- *Aprendizaje No Supervisado*. Estos tipos de redes no tienen una referencia de comparación por lo cual contemplan la autoorganización, autoasociación, etc., como proceso de obtención de la salida de la red.

c) **Según su aplicación**, se clasifican en:

- *Redes de Clasificación*. Las redes de clasificación hacen uso del aprendizaje no supervisado para obtener patrones de clasificación a base de las entradas del problema.
- *Redes de predicción*. Las redes de predicción tienen como objetivo modelar una función no lineal.

Otros tipos son redes de memoria asociativa, mapeo de características, reconocimiento de patrones y optimización.

### 3.4. Parámetros de la red

Según [Pino02] se consideran ciertos parámetros para la elaboración de la red. A continuación, se mencionan las más importantes:

- **Topología de la red.** La topología de la red considera la cantidad y definición de las variables de entrada y salida del sistema a desarrollar, así como el modelo de red a utilizar, los más comunes son el perceptrón multicapa, los mapas kohonen, etc., así mismo se define la cantidad de neuronas y las funciones de activación en

cada capa de la red neuronal. A continuación, se mencionan los parámetros necesarios para la red.

**W<sub>ij</sub>**: Peso correspondiente de las neurona i hacia la neurona j

**W<sub>jk</sub>**: Peso correspondiente de las neurona j hacia la neurona k

**N**: Número de neuronas en la capa de entrada

**O**: Número de neuronas en la capa oculta

**Y**: Número de neuronas en la capa de salida

- **Algoritmo de aprendizaje.** Los algoritmos más comunes utilizados en el desarrollo de las redes neuronales son el backpropagation y todas sus variantes. El algoritmo presenta dos fases que son las siguientes:
  - Fase de Aprendizaje o Entrenamiento
  - Fase de Recuerdo

La idea es actualizar los pesos de la capa escondida por lo cual se retropropaga el error hacia las capa intermedia.

### 3.5. Ventajas

Las redes neuronales artificiales (RNAs) tienen muchas ventajas debido a que están basadas en la estructura del sistema nervioso, principalmente el cerebro. [Jaramillo+05]. A continuación, se mencionan las más importantes:

- **Aprendizaje.** Las RNAs tienen la habilidad de aprender mediante una etapa que se llama etapa de aprendizaje. Esta consiste en proporcionar a la RNA datos como entrada, a su vez que se le indica cuál es la salida (respuesta) esperada.
- **Auto organización.** Una RNA crea su propia representación de la información en su interior, descargando al usuario de esto.
- **Tolerancia a fallos.** Debido a que una RNA almacena la información de forma redundante, ésta puede seguir respondiendo de manera aceptable aun si se daña parcialmente.
- **Tiempo real.** La estructura de una RNA es paralela, por lo cual, si esto es implementado con computadoras o en dispositivos electrónicos especiales, se pueden obtener respuestas en tiempo real.

### **3.6. Herramienta de aplicación**

#### **LENGUAJE MATLAB**

MATLAB es un lenguaje técnico para aplicaciones computacionales que permite integrar computación, visualización y programación en un ambiente fácil de usar y en donde las soluciones son expresadas en notación matemática.

- **Toolboxes.** Es una caja de herramientas que trae incorporado el MATLAB. Este presenta numerosos modelos matemáticos, con demos incluidos. Dentro de esta herramienta se encuentra el **NEURAL NETWORK**, que es un administrador de tipos de redes neuronales, este contiene demos y un panel de administración de nuevas redes con sus parámetros respectivos la cual es muy útil para el trabajo con redes neuronales artificiales.



# Capítulo 4

## Estado del arte

El presente capítulo muestra lo existente en relación al problema que resolverá la presente tesis, inicia con la taxonomía del pronóstico, la cual permitirá tener una mejor visión del problema, luego se mencionan las áreas en que estos problemas pueden ser resueltos, así también algunas aplicaciones y casos de estudios que se han realizado hasta el momento, seguidamente se muestran los métodos utilizados para efectuar pronóstico, tanto los estadísticos como las RNAs.

### 4.1. Taxonomía

Existen 2 tipos de clasificación de pronóstico: según el horizonte definido y según el tipo de pronóstico. A continuación, se detalla cada uno de estos tipos:

#### 4.1.1. Según el horizonte definido [Edelman 02]

- **Pronóstico a corto plazo.** Este tipo de pronóstico tiene un lapso de hasta un año, pero es generalmente menor a tres meses. Se utiliza para planear las compras, programación de planta, niveles de fuerza laboral, asignaciones de trabajo, niveles de producción, resumiendo decisiones operativas; por ejemplo, la demanda continua de cierto producto.
- **Pronóstico a mediano plazo.** Es un pronóstico de rango mediano o intermedio, generalmente con un lapso de tres meses a tres años. Es valioso en la planeación de producción y presupuestos, planeación de ventas, presupuestos de efectivo, el análisis de varios planes de operación, resumiendo decisiones tácticas; por ejemplo, el tiempo requerido para prever la sustitución de una línea de productos por otra nueva.
- **Pronóstico a largo plazo.** Generalmente con lapsos de tres años o más, los pronósticos a largo plazo se utilizan para planear nuevos productos, desembolsos de capital, localización e instalaciones, la investigación y el desarrollo, resumiendo decisiones estratégicas; por ejemplo, para decidir la ampliación de instalaciones productivas.

#### 4.1.2. Según el tipo de pronóstico [Serna 03]

- **Pronósticos económicos.** Son aquellos pronósticos que marcan el ciclo del negocio al predecir las tasas de inflación, oferta de dinero, nuevas construcciones y otros indicadores de planeación.

- **Pronósticos tecnológicos.** Éstos tienen que ver con las tasas de progreso tecnológico, que pueden dar por resultado el nacimiento de productos novedosos que requieren nuevas plantas y equipos.
- **Pronósticos de demanda.** Son proyecciones de la demanda para los productos o servicios de una compañía. Estos pronósticos, también llamados pronósticos de ventas, conducen la producción de una compañía, la capacidad y los sistemas de programación, y sirven como insumos a la planeación financiera de mercado y de personal.

Algunas clases de pronósticos pueden referirse a: una industria entera, una línea de productos, o una marca individual; también pueden aplicarse a la totalidad de un mercado o segmento en particular [Edelman02].

El problema a resolver se ubica dentro del pronóstico de la demanda a corto y mediano plazo, ya que el horizonte de predicción abarca la estimación de la demanda de un producto desde un determinado mes hasta 1 año; por otro lado, se desea conocer la demanda continua de un producto o de toda una línea de productos para un segmento en particular (Lima y Callao), por lo cual está orientado a una fracción de población determinada.

## 4.2. Aplicaciones

El uso de pronósticos de demanda es inevitable en el servicio al cliente, ya que es el objetivo final de las cadenas de suministro de gran consumo. Mejorando el Nivel de Servicio no sólo se aumenta el espacio disponible, sino que en muchos casos genera una mejora financiera sorprendente, por lo cual el pronóstico de la demanda es fundamental. Algunas áreas de aplicación son las siguientes [Serna03]:

- Finanzas: Por ejemplo en la de demanda de dinero.
- Generación de energía: Planeación de sistemas de energía eléctrica [Jaramillo+05].
- Medicina: Pronóstico de personas con una determinada enfermedad.
- Recursos del agua: Pronóstico de la demanda del consumo de agua.
- Ciencias ambientales.
- Transporte: Demanda de transporte de carga en área urbana.
- Industria y Comercio: Demanda de productos [Morwitz+00].

Por ejemplo un hospital debe de predecir la demanda del número de pacientes. Esta información se usa en la toma de decisiones operativas, como el número de personal sanitario en los turnos, quirófanos o necesidad de medicamentos. Por otro lado un sistema

escolar debe de predecir la demanda del número de estudiantes, así podrá prever el número de profesores, aulas y servicios.

A continuación, daremos a conocer algunos campos de aplicación de los pronósticos de la demanda de productos y de la energía eléctrica.

#### **4.2.1. Predicción del consumo de fármacos a partir de redes neuronales artificiales [Palmer05]**

El propósito del presente estudio fue mostrar cómo una red neuronal artificial (RNA) puede ser útil para predecir el consumo de éxtasis. Específicamente, se trata de desarrollar una red neuronal del tipo backpropagation capaz de discriminar entre quién consume éxtasis y quién no, a partir de las respuestas dadas por los sujetos a un cuestionario.

La muestra estaba compuesta por 148 consumidores y 148 no consumidores de éxtasis. Se explican las diferentes fases llevadas a cabo para desarrollar la RNA:

- Selección de las variables relevantes y preprocesamiento de los datos
- División de la muestra en grupo de ensayo, validación y test
- Ensayo y evaluación del modelo de red
- Análisis de sensibilidad

La eficacia de la RNA entrenada fue del 96.66%. El área bajo la curva ROC (Receiver operating characteristic) fue de 0.9944. Por otra parte, con dicho trabajo se pretende mostrar que las RNA no representan una "caja negra", sino que pueden dar información acerca del grado de influencia que tiene cada variable predictora sobre el consumo de éxtasis.

#### **4.2.2. Sistema híbrido para pronosticar demandas de producto de telecomunicaciones [Cox+02]**

Un desafío crucial para las empresas de telecomunicaciones es cómo pronosticar cambios de la demanda de productos específicos durante los 6 a 18 próximos meses: la longitud de una planificación, capacidad de gama corta típica y la hechura de un presupuesto, capital que planea el horizonte. El problema es, sobre todo, el acento agudo cuando sólo las historias cortas de ventas de producto están disponibles. Este papel presenta un acercamiento nuevo de dos niveles al pronóstico de la demanda de datos a corto plazo. Uno de los niveles consiste en algoritmos de identificación de sistemas adaptables tomados prestado del tratamiento de señal. Aunque ellos principalmente hayan sido usados en la ingeniería, como el reconocimiento de discurso automatizado y la informática sísmica, las técnicas también parecen ser muy prometedoras para predecir las probabilidades de comportamientos de cliente individuales de las muestras relativamente cortas de historias recientes adquisitivas de producto.

El nivel superior de nuestro acercamiento aplica un algoritmo de árbol de clasificación para combinar la información del nivel inferior que pronostica algoritmos. En contraste con otros algoritmos de combinación pronóstico, como ponderado haciendo un promedio o fórmulas de agregación Bayesiana, el árbol de clasificación se acerca a interacciones de orden alta (pedido alto) de proezas entre el modelo de error de sistemas proféticos diferentes. Esto crea un híbrido, pronosticando el algoritmo que supera cualquiera de los algoritmos individuales en los que es basado. Este acercamiento basado por árbol a pronósticos de hybridizing proporciona un modo nuevo, general de combinar y mejorar pronósticos individuales, si realmente ellos son basados en varios algoritmos. El papel concluye con los resultados de las pruebas de validación.

#### **4.2.3. Un modelo Spline para el pronóstico de la demanda de energía eléctrica[Barrientos+07]**

El propósito del modelo es pronosticar la demanda diaria de energía eléctrica en una región del suroccidente colombiano, mediante modelos de regresión no paramétrica, teniendo en cuenta factores de influencia tales como: la hora del día, día de semana, mes y año, entre otros. Los datos que se emplearon provienen de una compañía local de distribución de energía eléctrica y se tomaron de Valencia (2005), la información disponible va desde la energía de 2001 hasta noviembre de 2004.

El estudio se debió a que el constante desarrollo de los mercados de energía eléctrica genera escenarios cada vez más competitivos, por lo que es de crucial importancia poseer sistemas de distribución con planes de manejo bien estructurados. El objetivo es disponer de sistemas que suministren energía eléctrica con el menor número de interrupciones y al menor costo posible, mejorando así la calidad del servicio.

La calidad de los pronósticos obtenidos a partir de los modelos spline basados en el horizonte del mes anterior indica que, para realizar predicciones de la demanda de energía eléctrica del Valle de Cauca en el corto plazo, es suficiente contar con información reciente.

No es razonable plantear un modelo multivariante de series de tiempo con VAR (Vectores Autorregresivos) para un día en particular, puesto que cada serie horaria está conformada por datos de demanda registrados en tiempos diferentes, en otras palabras, estas series no son equivalentes en el tiempo.

### **4.3 Métodos de pronóstico**

En la actualidad, las clasificaciones de los métodos de pronóstico se basan en dos grandes enfoques: el enfoque cuantitativo y el cualitativo. A continuación, mencionaremos cada uno de los métodos pertenecientes a dichos enfoques.

### 4.3.1 Métodos cuantitativos

Este tipo de métodos se emplean cuando la situación es estable y existen datos históricos. Así mismo requieren técnicas estadísticas o herramientas matemáticas. Entre algunas de ellas tenemos [Jaramillo+05]:

- Análisis de series de tiempo
- Promedio de movimiento simple
- Promedio de movimiento ponderado
- Ajuste exponencial
- Análisis de regresión lineal
- Método Winters
- Técnica de box Jenkins
- Serie de tiempo de Shiskin
- Modelos de simulación

A continuación, se explicará en qué consisten algunos de los métodos más conocidos.

#### 4.3.1.1. Análisis de series de tiempo [Ofir87]

Esta metodología se utiliza para analizar los patrones de demanda como: tendencia, estacionalidad, ciclos, autocorrelación del pasado y llegar a hacer pronósticos para el futuro, es decir, se basa sustancialmente en datos históricos. Es por ello que esta técnica funcionará si las utilidades y tendencias del producto que la empresa venda son estables y claras. Es una secuencia de datos uniformemente espaciada que se obtiene observando las variables en períodos de tiempos regulares. Se trata de una previsión basada en los datos pasados, supone que los factores que han influido en el pasado lo sigan haciendo en el futuro.

#### Ejemplo:

Año:	1993	1994	1995	1996	1997
Ventas:	78,7	63,5	89,7	93,2	92,1

Se consideran ciertos factores para llevar a cabo la predicción:

- **Tendencia.** Es el movimiento gradual de ascenso o descenso de los datos a lo largo del tiempo. Los cambios en la población, ingresos, etc., influyen en la tendencia de varios años de duración.
- **Estacionalidad.** Es una muestra de datos de ascenso o descenso que se repite que se puede ver afectada por la climatología, las costumbres, etc., y que se produce dentro de un período anual.

- **Ciclos.** Movimientos de ascenso o descenso que se repiten que se pueden ver afectados por interacciones de factores que influyen en la economía, suelen durar de 2 a 10 años.
- **Variaciones aleatorias.** Son “saltos” en los datos causados por el azar y situaciones inusuales que son debidas a variaciones aleatorias o a situaciones imprevistas: plagas, desastres naturales, desastres provocados por la mano del hombre, etc. Son de corta duración y no se repiten.

#### 4.3.1.2. Promedio de movimiento simple [Jaramillo+05]

Una media móvil simple (MMS) combina los datos de demanda de la mayor parte de los periodos recientes, siendo su promedio el pronóstico para el período siguiente. Una vez calculado el número de periodos anteriores a ser empleado en las operaciones, se debe de mantener constante. Se puede emplear una medida móvil de tres periodos de 20, pero una vez que se toma la decisión hay que continuar usando el mismo número de periodos.

Después de seleccionar el número de periodos a ser usados se dan pesos iguales al las demandas para determinar el promedio. El promedio se mueve en el tiempo en el sentido de que al transcurrir un período la demanda del primero más antiguo se descarta, y se agrega la demanda para el período más reciente para la siguiente operación. Una media móvil simple de n periodos se puede expresar mediante:

$$\text{MMS} = \frac{\text{Suma de las demandas anteriores de los últimos } n \text{ periodos}}{\text{Número de periodos empleados en la media móvil}}$$

$$\text{MMS} = \frac{\sum_{t=1}^n D_t}{N} = \frac{D_1 + D_2 + \dots + D_n}{N}$$

Donde:

t = 1 es el periodo más antiguo en el promedio de n periodos;  
t = n es el periodo más reciente.

La mayor *desventaja* al calcular el promedio es que hay que incluir como datos todos los elementos individuales, ya que un nuevo período de pronóstico implica agregar los nuevos datos y eliminar los más viejos. Para un promedio variable de tres a seis semanas esto no es tan grave, pero sería enorme la cantidad de datos para elaborar el gráfico de un promedio de sesenta días para la utilización de cada uno de los 20.000 artículos en inventarios.

#### 4.3.1.3. Ajuste exponencial.

En los anteriores métodos de pronósticos, el mayor inconveniente es que siempre se debe acarrear una gran cantidad de datos. En estos métodos, cada vez que se añaden un nuevo dato, se elimina la observación más antigua y se calcula el nuevo pronóstico. Si es válida la premisa, que la importancia de los datos disminuye

cuantos más antiguos sean, el método más lógico y fácil de usar puede ser el suavizamiento exponencial.

En el método sólo se necesitan tres datos: el pronóstico más reciente, la demanda real que se presentó para ese período, y una constante de suavizamiento alfa ( $\alpha$ ). Esta constante determina el nivel de suavizamiento y la velocidad de reacción ante las diferencias entre pronósticos y hechos. Cuanto más rápido sea el crecimiento, mayor debe ser la tasa de reacción.

Una desventaja del suavizamiento exponencial simple es que retrasa los cambios en la demanda.

#### 4.3.1.4. Análisis de regresión lineal [Levis +05]

Se define a la *regresión* como una relación funcional entre dos o más variables correlacionadas y se usa para pronosticar una variable con base en la otra. En la regresión lineal la relación entre las variables forma una línea recta. La línea de regresión lineal es de la forma  $Y = a + bX$ , donde  $Y$  es la variable dependiente que queremos resolver;  $a$  es la intersección de  $Y$ ;  $b$  es la pendiente y  $X$  es la variable independiente.

Los valores de  $a$  y  $b$  se obtienen de calcular, donde  $n$  es la cantidad de datos analizados:

$$a = \frac{n(\sum X Y) - (\sum X)(\sum Y)}{n(\sum X^2) - (\sum X)^2}$$

$$b = \frac{n(\sum X tDt) - (\sum Xt)(\sum Dt)}{n(\sum X^2 t) - (\sum X t)^2}$$

La regresión lineal es útil para pronósticos a largo plazo de sucesos importantes. La restricción principal para usar los pronósticos de regresión lineal es que los datos pasados y las proyecciones caen sobre una línea recta. En una parte del procedimiento se estima lo adecuado del ajuste de la línea con los datos. Se usa tanto para pronóstico de series de tiempo como para pronóstico de relaciones causales.

#### 4.3.2 Métodos cualitativos

Los métodos cualitativos se emplean cuando la situación no es clara y hay pocos datos. Se requiere de intuición y experiencia. A continuación, tenemos los siguientes métodos [Thompson+98]:

- Proyección fundamental
- Investigación de mercado
- Analogía histórica

- Consenso de grupo
- Método Delphi
- Modelos causales

Teniendo en cuenta que estos métodos son teóricamente para pronósticos, y que debido al análisis poco objetivo con el que se trabaja pueden no resultar eficientes, no han sido utilizados para aplicaciones trascendentes en los pronósticos. Por tanto, estos métodos no son utilizados actualmente en las empresas para realizar sus pronósticos, si se desea conocer en qué consisten estos métodos revisar [Thompson+98].

## 4.4 Redes neuronales artificiales

Las redes neuronales también es una técnica usada para pronósticos de la demanda. Hay varios tipos de redes neuronales pero, de acuerdo a las características mencionadas en el capítulo anterior, se tiene algunas redes que han sido utilizadas para pronosticar. Entre ellas tenemos:

- Perceptrón multicapa
- Red de Elman
- RBF (Red de Base Radial)
- Red de Jordan

A continuación, presentaremos cada una de ellas.

### 4.4.1 Perceptrón multicapa

La arquitectura del Perceptron Multicapa (PM ) surge en una combinación de esfuerzos de diversos autores ([Werbos74], [Werbos88], [Werbos89], [Parker85], [Parker87], [Rumelhart86]) por corregir las limitaciones que las redes iniciales, Adaline y Perceptron, tenían sobre todo en cuanto a separabilidad de funciones no lineales.

Una de las ventajas de este tipo de red, tal como se demostró en 1989, por Cybenko y Hornik, entre otros, es que es un aproximador universal de funciones, de modo que cualquier función continua en el espacio multidimensional real se puede aproximar mediante una red PM, también es de relativa dificultad de uso y aplicación, dado que es una red sin recurrencias y feed-forward. Posee además una elevada capacidad de generalización y robustez, que provoca que la pérdida de una neurona no afecte al resultado.

Es por ello que, aunque no sea la solución óptima en muchos casos, sobre todo por su elevado tiempo de entrenamiento en estructuras complejas, esta red está ampliamente extendida, teniendo aplicaciones en campos como:

- El reconocimiento del habla
- El reconocimiento óptico de caracteres
- El control de procesos



- La predicción de series temporales
- La conducción de vehículos




Figura 4.1. Red Perceptron Multicapa. Conexión feed-forward [Werbo89]

La arquitectura del PM está basada en una red feed-forward o con conexiones hacia delante, en la que se disponen de 3 tipos de capas:

- La capa de entrada, en la que las neuronas actúan como buffer y no se disponen de pesos ni umbrales.
- Las capas ocultas.
- La capa de salida, que actúa como un buffer de salida.

Todas las neuronas de la red (excepto las de la entrada, en general) llevan asociado un umbral. Además, cada neurona de una capa tiene conexiones con todas las de la capa anterior, aunque puede suceder que en ciertos casos no sea así, y que el peso de una conexión sea 0, es decir, que no exista. El entrenamiento de este tipo de redes, es decir, su aprendizaje, se realiza utilizando el algoritmo de Retropropagación.

#### 4.4.2 Red Elman – Jordan

Las redes Elman y Jordan, definidas por los investigadores del mismo nombre, son redes parcialmente recurrentes, es decir, son redes con conexión feed-forward, a las que se le han añadido algunas conexiones hacia atrás.

Tanto en la red Elman como en la Jordan, la arquitectura básica de la red es básicamente una red feed-forward, y, en concreto, una PM, dado que las activaciones de todas las neuronas son saturantes. Sin embargo, de todas las entradas de las que se dispone en la capa de entrada alguna son utilizadas para recoger la información que disponían otras neuronas en el instante anterior. Estas neuronas se denominan entradas de contexto, dado que hacen referencia al estado anterior de la red. En la Figura 4.2 se muestra la arquitectura de la red de Elman.




Figura 4.2. Arquitectura de la red de Elman [Broomhead+88]

La diferencia principal entre los dos tipos de arquitectura está en la información que se transmite a las entradas de contexto. En las redes Elman se realimentan las salidas de las neuronas de la última capa oculta, de modo que, en cierto sentido, la red dispone de información acerca de la entrada del instante anterior.

En las redes Jordan, sin embargo, existe una doble recurrencia. Por una parte se realimentan las salidas del instante anterior ponderadas con un parámetro fijo  $\mu$ , y, además, cada neurona de contexto recibe una copia de su estado anterior. El parámetro  $\mu$  determina el horizonte de la memoria de la red, es decir, determina la ventana de tiempo que recuerda la red, de los datos de salida.

El aprendizaje de estos dos tipos de redes se basa en el algoritmo de retropropagación, dado que a la hora de entrenar se desacoplan los bucles. De este modo, inicialmente se calculan las salidas y se hallan los datos para pasar a las neuronas de contexto. En el siguiente instante, se consideran estos datos como entradas a la red, y se aplica de nuevo el algoritmo, y así sucesivamente.

### 4.4.3 Red de base radial

Creadas por M.J.D. Powell, D.S. Broomhead y D. Lowe a mediados de los 80 [Broomhead+88] las redes de Base Radial plantean una filosofía de neuronas muy diferente a las del resto de arquitecturas de red.

A diferencia de las redes Perceptron, las redes de Base Radial o redes BR son arquitecturas que disponen únicamente una capa oculta, con lo que en total, suman 3 capas: entrada, oculta y salida. Al igual que en las PM, cada neurona de una capa tiene conexión con todas las neuronas de la capa siguiente, aunque no existen pesos de la entrada a las neuronas ocultas.




Figura 4.3. Red de Base Radial. Conexión feed-forward [Broomhead+88]

Sin embargo, la principal diferencia de las redes BR con el resto de redes está en el propio funcionamiento de las neuronas. Mientras que en las redes PM las funciones de activación son de carácter saturante, en las redes BR las funciones de activación son radiales, es decir, se define un centro para cada neurona de la capa oculta que hace que la neurona tome un elevado valor de activación cuando las entradas estén cerca de dicho centro, y bajo cuando la distancia al centro sea mayor. Las neuronas de la capa de salida, sin embargo, disponen de funciones de activación lineales y actúan como meros sumadores.

El entrenamiento de las redes de BR consiste en “distribuir” las neuronas a lo largo del espacio de entrada, de forma que entre todas sean capaces de generar la función, pero cada una en el tramo que le corresponda. Para ello, existen algoritmos específicos que calculan directamente los centros de las neuronas de la capa oculta, con el fin de distribuirlas adecuadamente en el hiperespacio de entrada. Sin embargo, también es posible utilizar técnicas basadas en el algoritmo de Retropropagación para entrenarlas, dado que también constituyen redes feed-forward.

En general, estas redes son más rápidas de entrenar que las redes PM y pueden constituir una buena elección en problemas con un número pequeño de entradas, dado que, al disponer de una única capa, si se eleva mucho el número de entradas, el número de neuronas ocultas se incrementa exponencialmente.

## 4.5. Casos de estudio

### 4.5.1. Sistema demand forecasting

El sistema Demand Forecaster ofrece técnicas de predicción poderosas que se presentan en un ambiente gráfico que permite detectar de forma automática temporadas, modas, artículos con movimiento lento, datos extremos e inusuales y grandes cambios en la demanda. Su motor estadístico “aprende solo” y requiere de mínima intervención para desarrollar pronósticos exactos de la demanda. Esta solución flexible y escalable permite pronosticar con cualquier combinación de grupos de productos, clientes o canales y puede funcionar en un solo sitio o a través de la empresa. Las promociones y los eventos permiten determinar y modelar el impacto de los cargos adicionales y la canibalización, mientras que los escenarios alternativos ayudan a calcular el impacto de éstos en el suministro posterior. El resultado es un plan de la demanda y suministro completamente coordinado que asegura los niveles más altos de servicio a clientes.

Al trabajar con Infor, uno de los mejores fabricantes farmacéuticos del mundo, ha mejorado la exactitud de sus proyecciones hasta en 30%. Esto dio como resultado una disminución de las existencias de aproximadamente 15% en sus sitios de manufactura, a la vez que mantuvieron el 99.6% de fiabilidad en la entrega.

### 4.5.2. Sistema de pronóstico de la demanda en Whirlpool Argentina

El modelo utilizado se muestra a continuación en la Figura 4.4.:

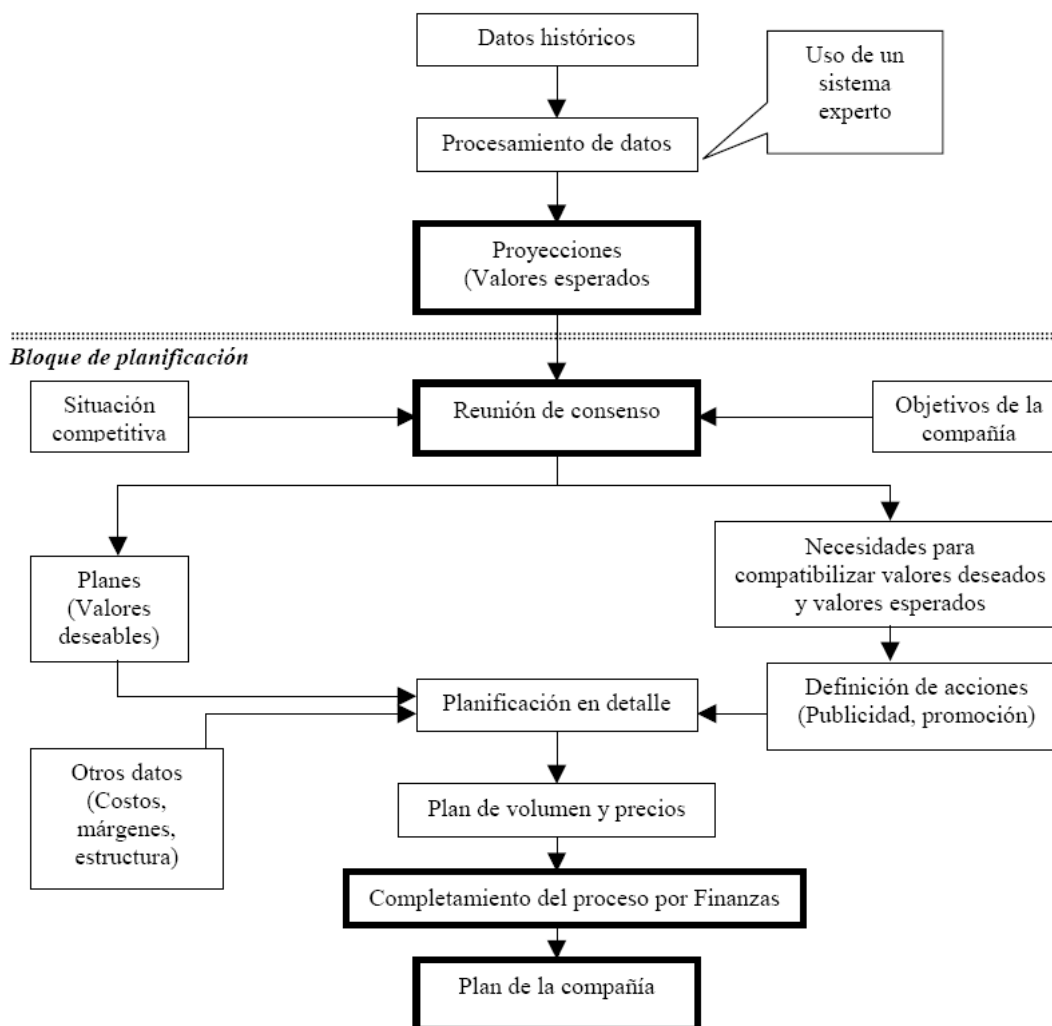


Figura 4.4. Modelo del proceso de pronóstico y planificación

Modelo Utilizado: ARIMA

Pruebas: Al comparar el pronóstico de los modelos ARIMA con el resultado real se comprobó, para la mayoría de las 13 series analizadas, que los errores porcentuales rondaban en promedio el 15%. El sistema requiere un mínimo de 4 años de datos.

**4.5.3. Predicción de la demanda eléctrica horaria mediante redes neuronales artificiales [Jaramillo+05]**

Este trabajo realizado muestra a continuación un completo desarrollo del tema.

**- Arquitectura de la red**

La red que se propone está compuesta por tres capas: Una de entrada, una oculta y una de salida. En lo referente a la capa de entrada, se ubicaron en la misma seis unidades que representarán cada uno de los factores explicativos seleccionados. La capa de salida sólo contará con una unidad, la cual indicará el valor de la carga eléctrica horaria asociado a cada vector de inputs presentado a la red. Finalmente, la capa oculta contará con un número variable de neuronas. Esquemáticamente, el modelo de red neuronal artificial para la curva de carga tendría la siguiente forma que se muestra en la Figura 4.5:

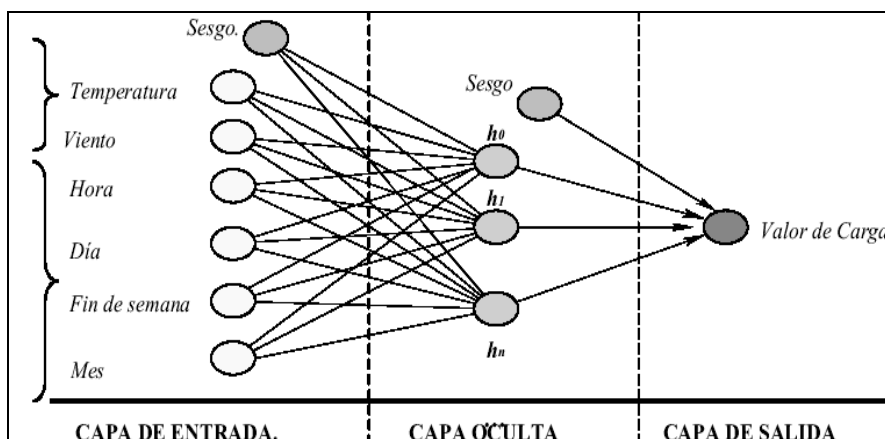


Figura 4.5. Arquitectura de la red PMC

La determinación del número óptimo de neuronas de la capa oculta se ha llevado a cabo mediante un proceso de ensayo y error en el que se jugó con el número de neuronas y el máximo error admisible. El objetivo era dotar a la red de un número adecuado de neuronas en la capa oculta para que sea capaz de aprender las características de las posibles relaciones existentes entre los datos de la muestra.

- **Datos de entrada**

La información de las variables se presenta en la Tabla 4.1 que se muestra a continuación:

CATEGORÍA	VARIABLE	UNIDADES	TIPO
CLIMÁTICAS	Temperatura	C°	Numérica. Representada por su valor actual.
	Viento	m /sg.	Numérica. Representada por su valor actual.
CALENDARIO	Hora	-	Numérica. Representada por su valor actual. Rango = (0-23)
	Día	-	Categorica. Codificada: Lunes = 0, Martes = 1,..., Domingo = 6.
	Fin de Semana	-	Numérica binaria. Fin de semana ó festivo = 0 ./ Día laborable =1
	Mes	-	Categorica. Codificada: Enero = 0, Febrero = 1,..., Diciembre = 11
OBJETIVO	Carga Eléctrica	GW/Hora <sup>10</sup>	Numérica. Representada por su valor actual.

Tabla 4.1. Descripción de las variables de entrada

Dado el nivel de desagregación requerido (valores horarios), la obtención las series de datos referidas a la carga eléctrica y a las variables climáticas consideradas (temperatura y de velocidad del viento), ha sido una tarea especialmente laboriosa. Finalmente, consiguieron esta información en las páginas Web de NOAA (*National Oceanic and Atmospheric Administration*) y de ATDD (*Atmospheric Turbulence and Diffusion Division*).

- **Entrenamiento de la red**

El entrenamiento lo llevaron a cabo utilizando una muestra de 8760 observaciones, y para llegar a determinar el valor óptimo de los parámetros que definen la red recurrieron al método de ensayo y error.

- **Número óptimo de iteraciones.** La aportación de cada nueva iteración en términos de reducción del error cuadrático medio es despreciable a partir de las 200 iteraciones.
- **Número óptimo de neuronas en la capa oculta.** Pudo ser determinado mediante la aplicación de una serie de fórmulas heurísticas o,

alternativamente, mediante un proceso de ensayo y error. En este trabajo decidieron optar por la segunda opción. Para llevar a cabo el experimento fijamos la tasa de aprendizaje y el valor del momento. Los experimentos realizados revelaron que el número óptimo de neuronas de la capa oculta estaría situado en torno a 8, teniendo en cuenta el número de vectores con el que se han realizado los entrenamientos (8760).

- **Valor óptimo de la tasa de aprendizaje.** Fijando todos los parámetros que inciden en el entrenamiento de la red salvo la tasa de aprendizaje, se llegó a la conclusión de que el valor óptimo de este parámetro se situaría en torno a 0.7.
- **Valor óptimo del momento.** Repitiendo una vez más el mismo proceso ya explicado, se obtuvo como valor óptimo del momento un valor situado en torno a 0.6.

En resumen, los valores óptimos que definen el entrenamiento del modelo neuronal se muestran en la Tabla 4.2.

Valores óptimos de los parámetros del entrenamiento <sup>14</sup>	
Iteraciones	200
Neuronas Ocultas	8
Tasa de Aprendizaje	0.6-0.8
Momento	0.4-0.6

Tabla 4.2. Valores óptimos de los parámetros del entrenamiento.

Luego, la predicción de la demanda eléctrica se muestra en la Figura 4.6, en la cual se nota 2 curvas, donde una pertenece a la demanda observada y otra a la demanda ajustada.

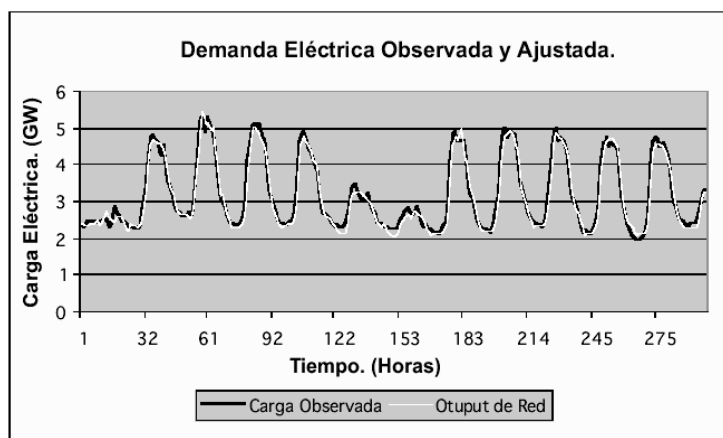


Figura 4.6. Curva de carga observada y la ajustada por el modelo en el entrenamiento demanda observada y ajustada

Luego los valores de los parámetros del entrenamiento se muestran en la Tabla 4.3.

Valores de los parámetros del entrenamiento	
Observaciones.	8760
Iteraciones	200
Neuronas Ocultas	8
T. de Aprendizaje	0.8
Momento	0.4

Tabla 4.3. Valores de entrenamiento

Atendiendo al gráfico se puede apreciar cómo la red neuronal reproduce con gran precisión la curva de carga original, con lo que se puede intuir que el entrenamiento ha resultado un éxito. Esta misma idea es corroborada por el error cuadrático medio, el cual toma un valor del 0.6%; por tanto podemos concluir que el entrenamiento ha sido un éxito. Veamos ahora cómo responde la red ante datos que le son desconocidos.

#### 4.5.3.1. Predicción con datos no conocidos por la red

A continuación, se presentó a la red el conjunto de datos que se había reservado previamente. La red procesará esta nueva información teniendo en cuenta las relaciones aprendidas en el entrenamiento y que guarda (recuerda) en forma de vector de pesos sinápticos. La salida de la red no será más que la predicción. Comparando esta predicción con el valor real de la carga podremos contrastar la capacidad predictiva del modelo.

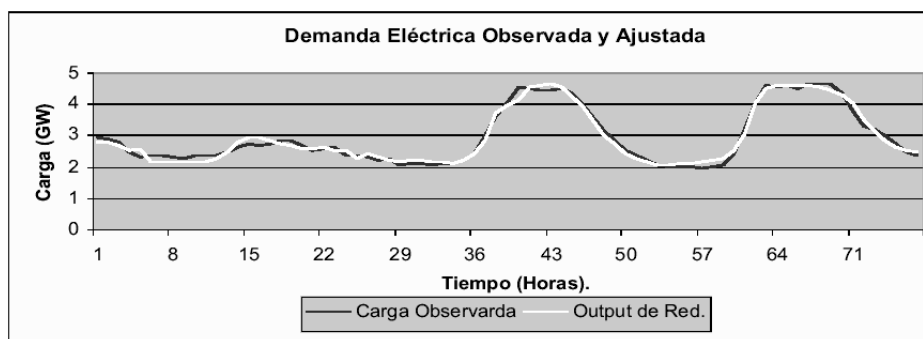


Figura 4.7. Representación de la curva de carga observada y la ajustada por el modelo con datos desconocidos.

Atendiendo a la representación gráfica se puede apreciar cómo el perfil de la curva de carga generada por la red se aproxima a la curva real con una precisión



aceptable. En cuanto al error cuadrático medio de la predicción (0,92%), tal y como cabía esperar es ligeramente superior a su homólogo en el entrenamiento, siendo lo suficientemente reducido como para admitir la capacidad predictiva del modelo. Así los resultados de la predicción se muestran en la Tabla 4.4.

Fase	Datos	Neuronas	$\lambda^{16}$	$\mu^{17}$	Iteraciones	$\sqrt{ECM}$
Entrenamiento	8760	8	0.8	0.5	200	7,73%
Predicción	360	8	0.8	0.5	200	9,64%

Tabla 4.4. Resultados de la predicción.

#### 4.5.3.2. Comparación con otros modelos

Finalmente, una vez superadas las fases de entrenamiento y validación, podemos comparar los resultados obtenidos a partir del modelo neuronal con los ofrecidos por otras técnicas más convencionales. De este modo podremos determinar en qué medida las RNA superan a las técnicas tradicionales como instrumento de modelización y predicción. A tal efecto hemos considerado los siguientes modelos:

- **Modelo ingenuo.** Modelo autoregresivo de primer orden,  $y_t = y_{t-1} + \varepsilon$   $\varepsilon \approx N(0, \sigma)$ .
- **ARMA.** Hemos identificado un modelo  $ARMA(2,2)$  x  $ARMA_s(24,24)$
- **Alisado Exponencial.** Alisado exponencial de Holt-Winters con  $\alpha=0.5$

Los resultados obtenidos aparecen recogidos en la Tabla 4.5.

	RNA	Modelo ingenuo	ARMA	Alisado exponencial
$R^2$ del modelo	0.64	0.90	0.93	0.94
$\sqrt{ECM}^{18}$	9,64%	29,91%	11,95%	14%

Tabla 4.5. Comparación con otros modelos.

#### 4.5.4. Pronóstico del déficit de viviendas en el estado de Mérida a través de redes neuronales artificiales [Gil08]

Esta investigación estuvo dirigida a construir un modelo que permitiese realizar el pronóstico del déficit de viviendas en el estado de Mérida, mediante la utilización de redes neuronales artificiales con Funciones de Bases Radiales (RBF). Para ello, fue necesario aplicar técnicas estadísticas de análisis multivariante, las cuales permitieron construir los indicadores para evaluar el carácter deficitario de las viviendas. Tomando los datos de las Encuestas de Hogares por Muestreo (EHM) correspondientes al período

1994-2005, se construyó un registro de datos que proporcionó los indicadores del número de hogares, tenencia, hacinamiento, adecuación y de la vivienda; para así proceder a la construcción de los modelos y, con esto, lograr el objetivo planteado.

**- Arquitectura de Base Radial**

Este tipo de redes se han asociado tradicionalmente con una arquitectura simple de tres capas, donde cada capa esta conectada unidireccionalmente con su capa consecutiva. Este modelo tiene la caracterización de poseer una sola capa oculta.

En la capa de entrada, como las emplean habitualmente las RNA, se encargan de enviar la información del exterior a las neuronas de la capa oculta. La capa oculta está compuesta de un conjunto de nodos a los cuales se le asocia una función de activación de tipo radial, denominada Funciones de Base Radial. Las funciones radiales reciben como entradas todos y cada uno de los atributos de los patrones, y se caracterizan por estar centradas en un punto del espacio de entrada.

En la capa de salida de la red se combina linealmente la salida de la función radial de la capa oculta, mediante unas ponderaciones.

Las RBF no son comúnmente utilizadas en aplicaciones que posean un alto volumen de patrones de entrenamiento. Sin embargo, se les reconoce por tener una eficiencia en la fase de entrenamiento. Enfocando un poco la idea del entrenamiento de las RBF se pueden describir como el aprendizaje por etapas, ya que en una primera fase se entrenan las neuronas ocultas y luego las de salida.

**- Modelo de la red con bases radiales (RBF)**

Al considerar el hecho que las RBF poseen una arquitectura muy simple, no puede emplear durante el entrenamiento, específicamente en su capa oculta. En este sentido, durante el entrenamiento correspondiente a ambos conjuntos de datos (94\_2-01\_1, 01\_2-05\_2), se observan características particulares producto de la diferencia existente en el tamaño de las muestras.

**- Definición de las entradas.**

Corresponde a las variables que se obtuvieron en el preprocesamiento. En la Tabla 4.6 se definen cada una de las variables con sus respectivos valores de las categorías.

um_Hogares	Tenencia	Hacinamiento	Adecuación	Condición
[1,2,3,4]	[0,1]	[0,1]	[0,1]	[0,1]

Tabla 4.6. Variables de entrada

### - Definición de la salida.

Para la RNA se define una sola variable de salida, la cual puede tomar las categorías enumeradas [0,1] indicando cada una el estado deficitario o no de la vivienda: Déficit= 1; No Déficit = 0.

En la Tabla 4.7 se definen las variables de salida.

VARIABLE DE SALIDA	DESCRIPCIÓN
<p><b>Vivienda no deficitaria:</b></p> <p>Representada en el conjunto de datos con cero. Incluye todas las observaciones que cumplan con todas y cada una de las condiciones para considerar una vivienda adecuada, señaladas en los apartados anteriores.</p>	<p>Viviendas en las que número de hogares que habitan la vivienda es sólo uno, la tenencia de la vivienda es propia, no hay hacinamiento, y la adecuación y condición de la vivienda es adecuada y buena respectivamente, para este caso se deben cumplir todas y cada una.</p>
<p><b>Vivienda deficitaria:</b></p> <p>Dentro del conjunto de datos registrada con un uno. Incluye todas las observaciones que no cumplan con al menos una de las condiciones de adecuación que han sido señaladas en los apartados anteriores.</p>	<p>Número de Hogares dos, tres, cuatro o más familias, tenencia alquilada, hay hacinamiento, adecuación inadecuada y condición mala.</p>

Tabla 4.7. Variables de salida

### - Selección de los patrones de entrenamiento.

Con la información recopilada se seleccionan patrones de entrenamiento y de prueba. La selección de las observaciones para los modelos RBF se hace mediante la técnica de muestreo aleatorio estratificado. Se tomaron diez muestras estratificadas de cada bloque de datos para el entrenamiento. Los tamaños fueron de trescientos setenta y ocho observaciones correspondientes al período 94\_2-01\_2 y novecientos setenta y ocho para el período 01\_2-05\_2. El resto de las observaciones fueron empleadas para las pruebas de los modelos.

### - Configuración de las capas del modelo RBF.

Debido a los fundamentos teóricos que señalan que este tipo de redes está constituido por una sola capa oculta, sólo es necesario configurar el número de centros de los nodos en la capa oculta del modelo. Así mismo, tomando en cuenta que el objetivo del estudio es analizar el pronóstico/clasificación del déficit de viviendas, sólo debe configurarse la función de activación en la capa de salida a ser empleada en el modelo que, por especificaciones también teóricas, se trata de una función lineal.

**- Fases de entrenamiento/prueba y validación de la red.**

Con los patrones seleccionados anteriormente se procede a entrenar la red. Recordando que se busca la mejor red, se toman un total de diez redes las cuales muestran el mejor desempeño. Una vez entrenada cada red se procede a la validación de la mejor red entrenada con el conjunto de datos no usado por la fase de entrenamiento.

**- Parámetros empleados para los modelos RBF del período 94\_2-01\_1 y 01\_2-05\_2**

A continuación, se muestran los pasos que se siguieron para la construcción del modelo con NeuroSolutions. Como se ha mencionado anteriormente, se tomaron dos bloques de datos para los cuales se lleva a cabo las mismas instrucciones requeridas por el NS en sus primeras fases, es decir, las salidas de entrenamiento relacionadas a las variables de entrada y salida del modelo. Los patrones de entrenamiento que se introducen son las muestras seleccionadas por estratificación para cada bloque de datos. En la Tabla 12 se da a conocer la estructura de los datos con una pequeña submuestra para ambos períodos, recordando que se tomaron 10 muestras para cada uno de ellos.

En la Tabla 4.8, los campos identificados con I, II, III, IV, V, OUT\_Y4, corresponden a cada una de las variables, ellas son: Num\_Hogares, Tenencia, Hacinamiento, Adecuación, Condición y la variable de salida respectiva empleada en el modelo.

Periodo 94_2-01_1						Periodo 01_2-05_2					
I	II	III	IV	V	OUT_y	I	II	III	IV	V	OUT_y
1	1	0	0	0	1	1	1	1	0	0	1
1	1	1	0	0	1	1	1	0	1	1	1
1	0	1	1	1	1	1	1	1	0	0	1
1	0	1	0	0	1	1	1	1	0	0	1
1	0	1	0	0	1	1	0	1	1	1	1
1	0	0	0	0	0	1	0	0	1	1	1
1	0	0	0	0	0	1	0	0	0	0	0
1	0	0	0	0	0	1	0	0	0	0	0
1	0	0	0	0	0	1	0	0	0	0	0
1	0	0	0	0	0	1	0	0	0	0	0
1	0	0	0	0	0	1	0	0	0	0	0
1	0	0	0	0	0	1	0	0	0	0	0
1	0	0	0	0	0	1	0	0	0	0	0
<b>Total datos</b>					378	<b>Total datos</b>					978

Tabla 4.8. Variables definidas para el modelo

En la Figura 4.8 se muestra la representación de la red de base radial propuesta, con la representación de las variables de entrada involucradas.

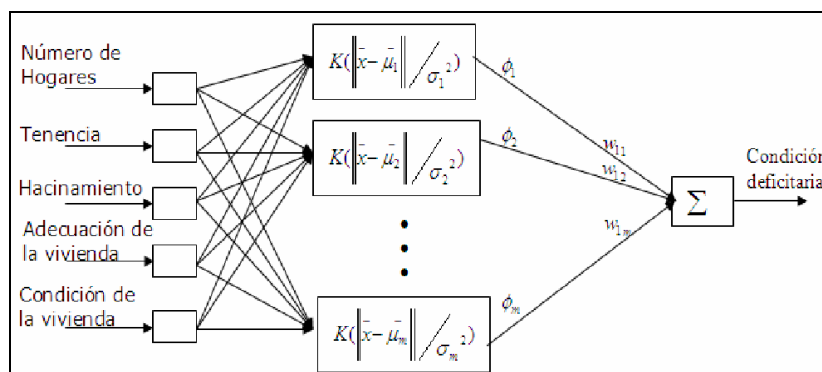


Figura 4.8. Representación del modelo de red RBF

Luego, en la Tabla 4.9 se muestra las características de la red, tales como: función de activación, regla de aprendizaje, etc. Y en la Tabla 4.10 se muestra las tasas de aprendizaje para ambos períodos. Los errores teóricos se muestran en la Tabla 4.11 para cada período con su respectivo número de ciclos.

<b>Función de Activación</b>	<i>LinealAxon</i>
<b>Regla de Aprendizaje</b>	<i>Momentum</i>
<b>Tamaño del Paso</b>	1.0000
<b>Variación de los Pesos</b>	0.7000

Tabla 4.9. Características de la red

Tasa de Aprendizaje			
Periodo	START	DECAY	CICLOS
94-01_1	0.01	0.001	100
01_2-05	0.01	0.001	100

Tabla 4.10. Tasa de aprendizaje para cada período

Error Teórico(94_01-2)	Error Teórico(01_05-2)	Ciclos
0,00001	0,00001	1000

Tabla 4.11. Error teórico de cada época

En la Tabla 4.12 se muestra los parámetros de la red para varios valores de nodos en la capa oculta y en la Tabla 4.13 se muestra el entrenamiento de la red.

Parámetros de la RBF						
Nº RED	Nº de entradas	Nº salidas	Nodos capa oculta	Nº obs.	Epochs propuesto	MSE propuesto
1	5	1	5	378	1100	0,0001
2	5	1	8	378	1100	0,0001
3	5	1	12	378	1100	0,0001
4	5	1	15	378	1100	0,0001
5	5	1	18	378	1100	0,0001
6	5	1	20	378	1100	0,0001
7	5	1	21	378	1100	0,0001
8	5	1	23	378	1100	0,0001
9	5	1	25	378	1100	0,0001
10	5	1	30	378	1100	0,0001

Tabla 4.12. Parámetros de la red

Entrenamiento				
Nº RED	MSE	RMSE	Epochs alcanzados	Orden de importancia
1	0,0001005	0,0001251	153	1
2	0,00018866	0,00023292	343	8
3	0,0001864	0,0002301	178	7
4	0,0001933	0,0002386	212	10
5	0,000178	0,00021975	225	3
6	0,00019093	0,00023572	277	9
7	0,00018532	0,0002288	283	5
8	0,0001861	0,00022983	218	6
9	0,000177587	0,00021924	221	2
10	0,00018347	0,00022651	230	4

Tabla 4.13. Entrenamiento de la red

#### 4.6. Normas legales

Para el caso de productos farmacéuticos se tienen una serie de normas impuestas en el Perú, ya que tenemos los productos farmacéuticos de venta libre (OTC – Over the counter) y los de venta con receta médica (éticos) [Indecopi 05].

Hoy en día el sector farmacéutico ha incrementado sus importaciones [Indecopi 05] y debido a ellos se toman una serie de medidas para evitar que los productos puedan llegar en mal estado, caducados o por otros motivos que causen un mal a la población.

Si se desea saber detalladamente todas las normas referentes a productos farmacéuticos, se puede revisar el anexo 2 de la Ley General de Salud.

## 4.7. Evaluación comparativa de métodos de pronóstico

### 4.7.1. Criterios de comparación

A continuación, se describen los criterios que permitirán evaluar los métodos de pronóstico de la demanda.

Tenemos los criterios de [Gaither+00] y [Petrovic+06].

El primero propone 6 criterios de selección para los métodos de pronóstico: costo, precisión, datos disponibles, lapso de tiempo, naturaleza de los productos y servicios, y respuesta de impulso y amortiguación de ruido; estos criterios son dados para pronosticar un producto en general y podemos considerarlos para los productos farmacéuticos.

#### - Costo

Los costos a considerar básicamente son:

- costo de desarrollar el modelo
- complejidad
- costo de conseguir los datos necesarios
- costo de la operación real de la técnica
- tipo de software requerido

En tanto los costos para pronosticar un producto pueden ser: *bajo, moderado o alto*.

#### - Precisión

Se sabe que para obtener más precisión en el pronóstico es necesario incurrir en un mayor costo. Los procedimientos de elevada precisión utilizan más datos, dichos datos por lo general son más difíciles de obtener y los diseños tienen un modelo más costoso, son más caros de poner en práctica y de operar.

Los pronósticos en cuanto a precisión pueden ser: *alta, adecuada y variable*.

#### - Datos disponibles

Los datos disponibles corresponden a los datos que estén disponibles y que sean relevantes para los pronósticos, ya que son un factor importante en la selección del método de pronóstico.

- Datos históricos--¿de cuántos períodos? ¿con qué frecuencia?
- Variables disponibles
- Exactitud de los datos (confiabilidad)
- Puntualidad de los datos (relevancia)

Se podría requerir un procedimiento para reunir los datos.

Por lo tanto, el requisito de la disponibilidad de los datos para realizar el pronóstico pueden ser: *muy bajo, bajo, alto*.

- **Tiempo**

En tiempo es el período en que el pronóstico se llevará a cabo y esto depende de la naturaleza del pronóstico. Por lo tanto encontramos:

- Corto plazo (1-3 meses)
- Medio plazo (>3 meses y < 3 años)
- Largo plazo ( $\geq 3$  años)

Entre más largo el plazo, menos exactos son los pronósticos cuantitativos y más valiosos los pronósticos cualitativos.

- **Naturaleza de los productos y servicios**

Es recomendable utilizar diferentes métodos de pronóstico para productos distintos. Factores tales como si el producto es de volumen y costo elevados, si el producto es un bien manufacturado o servicio, o en qué punto de su ciclo de vida está el producto, afecta la elección de un método de pronóstico.

- **Respuesta de impulso y amortiguación de ruido**

Debe equilibrarse lo que deseamos del modelo de pronóstico en lo se refiere a su respuesta, como por ejemplo, ante cambios en los datos reales de la demanda contra nuestro deseo de suprimir cualquier variación aleatoria indeseable, es decir, ruido en los datos.

El segundo criterio propone cuatro criterios para la selección del método de pronóstico: sofisticación del usuario y del sistema, tiempo y recursos disponibles, disponibilidad de datos y patrón de datos.

Dos de los criterios ya están considerados. Veremos en qué consisten los otros dos criterios.

- **Sofisticación del usuario y del sistema**

El método de pronóstico debe ajustarse a los conocimientos y sofisticación del usuario, debido a que los gerentes se rehúsan a utilizar los datos de técnicas que no comprenden.

El método que se elige no debe ser demasiado desarrollado ni sofisticado para sus usuarios y tampoco debe estar demasiado alejado del sistema de pronóstico actual. En ocasiones los modelos más simples pueden tener mejores resultados, por lo que la sofisticación no es el objetivo definitivo.



- **Patrón de datos**

Los datos se pueden comportar de diferentes formas a través del tiempo, puede que se presente una *tendencia, un ciclo*; no tener una forma definida o aleatoria, variaciones **estacionales** (anual, semestral, etc.).

**Patrón de datos con tendencia.** Son series cuyo valor medio cambia a lo largo de tiempo, de forma que se espera que aumente o disminuya durante el período para el que se desea hacer el pronóstico.

**Patrón de datos estacionales.** Son series cuyo valor medio no cambia a lo largo de tiempo, es decir, las series son relativamente estables.

**Patrón de datos cíclicos.** Son oscilaciones de los datos alrededor de la tendencia, es posible que los patrones no sean estables.

Una manera de detectar el patrón es trazar los datos sobre una gráfica como se muestra en la Figura 4.9.

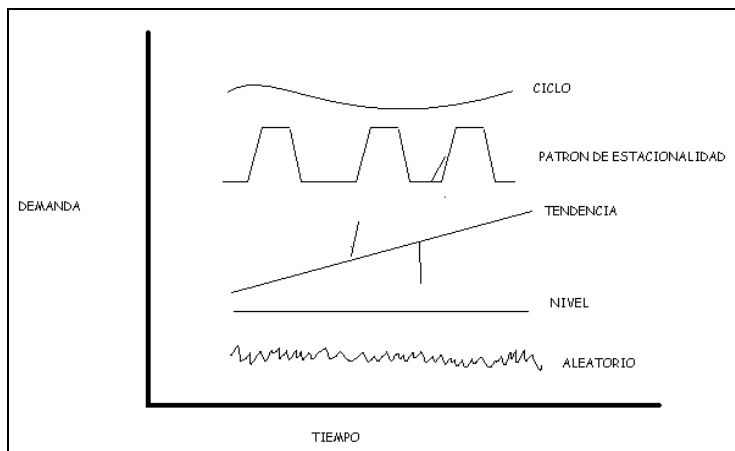


Figura 4.9. Comportamiento de patrones de datos en el tiempo [Wheelwright+76].

De acuerdo a las características del problema se cree conveniente agregar los siguientes criterios.

- **Tipo de modelo**

El tipo de modelo es importante, ya que definirá la complejidad relacional entre los parámetros involucrados. Así, tenemos modelos lineales y no lineales.

- **Relación de valores y puntaje por criterio**

En la Tabla 4.14 se lista los valores y el puntaje respectivo para cada criterio de comparación.

Hay 2 criterios que no hemos tomado en cuenta para la comparación de elección del método para pronósticos de productos farmacéuticos, que a continuación justificamos:

- **Naturaleza de los productos y servicios**

Este criterio define la naturaleza del problema, es decir, si trata de un producto o servicio y éstos a su vez de qué tipo son; en nuestro caso ya tenemos el problema y nosotros hacemos los criterios para productos farmacéuticos, por tanto ya no es necesario tomar en cuenta este criterio de defunción.

- **Sofisticación del usuario y del sistema**

Este criterio involucra mucho al usuario que usará el sistema con la metodología implantada. Para nuestro problema planteamos la elección de una técnica donde no se involucre al usuario o experto en el tema; por tanto, no necesitamos tomar en cuenta el conocimiento o sofisticación del usuario o sistema respectivamente.

#### 4.7.2. Relación de valores y puntaje por criterio

A continuación, se explicará los puntajes asignados a cada criterio definido.

Con respecto al **costo**, donde los métodos de costo bajo poseen un puntaje de 3, ya que se desearía que el costo sea lo más bajo posible pero teniendo en cuenta los factores que afectan al costo es fijo para todos los métodos, y el costo moderado tiene un puntaje de 2 debido que es un costo aceptable del proyecto para la aplicación de la metodología y el costo alto un puntaje de 1, ya que no un método tan costoso tampoco es recomendable como variables independiente.

Con respecto a la **precisión**, contamos con 3 valores: la precisión variable que se le asigna un puntaje de 1, ya que para un buen pronóstico esto no se debería dar; la precisión adecuada se le da un puntaje de 2, ya que se refiere a la precisión de pronóstico aceptable para el problema pero no la adecuada; y la precisión alta con un puntaje de 3, que representa el pronóstico más cercano a lo real.

El **criterio de datos disponibles** se refiere a la cantidad de datos de los que necesita disponer el método, es decir, los datos que requiere. Por tanto, el valor de muy bajo tiene un puntaje de 3, ya que mientras menos datos se necesitan, menos compleja es la implementación del pronóstico de la demanda. Con esta definición, al valor de datos disponibles bajo se le asigna un puntaje de 2, y al valor alto se le asigna un puntaje de 1.

Con respecto al **horizonte del tiempo** del pronóstico se tiene tres valores: a corto plazo se le asigna un puntaje de 2, ya que para nuestro problema podría proponerse ese tiempo pero no es nuestro objetivo; tiempo a mediano plazo se le asigna un puntaje de 3, ya que es el lapso que consideramos apropiado para el pronóstico de productos farmacéuticos; y el de largo plazo un puntaje de 1, ya que es un tiempo muy amplio para nuestro objetivo.

Al criterio de **amortiguación** de ruidos se le da dos valores de sí y no, con puntajes de 1 y 0 respectivamente; esto es, si el método consiente ruidos o disturbios en el comportamiento de los datos de entrada.

Con respecto al criterio de **patrón de datos** tenemos: los estacionales, a los que se le asigna un puntaje de 0, ya que son series de comportamiento casi contante; los de tendencia, a los que se le asigna un puntaje de 1, que es el comportamiento variado de nuestro producto a pronosticar; y el patrón cíclico, que le asignamos un puntaje de 1, que si bien se pueden repetir en varios años algunos datos, presenta patrones variables. Así, si el modelo acepta comportamiento estacional y tendencial, o estacional y cíclico, se le asigna un puntaje de 2; si acepta datos tendencial y cíclico se le asigna un puntaje de 3. Por tanto, si acepta los tipos de patrón de datos -tendencial, estacional, y cíclico- se le asigna un puntaje de 4.

Por último, tenemos al criterio de tipo de modelo, el cual presenta dos valores: el modelo lineal, al que se le asigna un puntaje de 1, debido a que la relación de nuestros datos no es lineal; y el modelo no lineal, con un puntaje de 2, ya que se acerca al comportamiento de los datos.

En la Tabla 4.14 se muestra los puntajes de los criterios de comparación:

<b>Criterio</b>	<b>Valores</b>	<b>Descripción</b>	<b>Puntaje</b>
<b>Costo</b>	Bajo	El método produce un costo bajo.	3
	Moderado	El método produce un costo aceptable.	2
	Alto	El método produce un costo alto.	1
<b>Precisión</b>	Variable	El método presenta resultados de precisión variable.	1
	Adecuada	El método presenta resultados de precisión adecuada.	2
	Alta	El método presenta resultados de precisión alta.	3
<b>Datos disponibles</b>	Muy bajo	El método requiere de muy pocos datos.	3
	Bajo	El método requiere de pocos datos.	2
	Alto	EL método requiere de muchos datos.	1
	Corto plazo	El método se implementa en menos de 3 meses.	2
	Mediano plazo	El método se implementa en menos de 3 años y mayor a 3 meses.	2

<b>Tiempo</b>	Largo plazo	El método se implementa en más de 3 años.	1
	Corto - mediano	El método puede ser de corto a mediano plazo.	3
	Mediano-Largo	El método puede ser de mediano a largo plazo.	3
<b>Amortiguación de ruidos</b>	No	El método no acepta ruidos en las entradas.	0
	Sí	El método acepta ruido en las entradas.	1
<b>Patrón de datos</b>	Estacional	El método soporta datos de comportamiento estacionario.	0
	Tendencial	El método soporta datos de comportamiento tendencial.	1
	Cíclicos	El método soporta datos de comportamiento cíclico.	1
	Estacional y tendencial	El método soporta datos de comportamiento estacionario y tendencial.	2
	Estacional y cíclico	El método soporta datos de comportamiento estacionario y cíclico.	2
	Tendencial y cíclico	El método soporta datos de comportamiento tendencial y cíclico.	3
	Estacional, tendencial y cíclico	El método soporta datos de comportamiento estacional, tendencial y cíclico.	4
<b>Tipo de modelos</b>	Lineal	Asume un comportamiento de la serie a priori.	1
	No lineal	Más grados de libertad para el modelo.	2

Tabla 4.14. Valores y puntaje por criterio de comparación de tipos de pronósticos

### **4.7.3. Cuadro comparativo**

Para la realización de asignación de valores de los criterios para cada método de pronóstico, se ha revisado las características de cada uno de ellos.

En caso de que los métodos no tengan asignados ningún valor de criterio, quiere decir que no se ha encontrado información suficiente para definir el criterio, por tanto el valor sería cero.

En la Tabla 4.15 se muestra el cuadro comparativo que refleja el resultado de la comparación.

Según la comparación realizada, las **redes neuronales** es la metodología más apropiada que cubre las características de criterio para el pronóstico de la demanda de productos farmacéuticos.

<b>Criterio/Modelo</b>	<b>Método cualitativos</b>	<b>Series de Tiempo</b>	<b>Promedios Móviles</b>	<b>Ajuste Exponencial</b>	<b>Regresión lineal</b>	<b>Modelos causales</b>	<b>Análisis de regresiones</b>	<b>Redes Neuronales</b>
<b>Costo</b>	Alto	Bajo	Bajo	Alto		Alto		Moderado
<b>Precisión</b>	Variable	Adecuada	Adecuada	Adecuada	Adecuada		Alta	Alta
<b>Datos Disponibles</b>	Alto	Alto	Bajo	Muy bajo	Alto		Alto	Ato
<b>Tiempo</b>	Largo	Corto y mediano	Corto y Mediano	Corto y Mediano	Largo	Largo		Mediano y Largo
<b>Amortiguación de ruidos</b>	No	No	No	No	No	No	No	Sí
<b>Patrón de datos</b>		Tendencial, estacional y cíclico	Estacional, tendencia	Tendencial	Tendencial		Estacional	Tendencial, estacional y cíclico
<b>Tipo de modelo</b>	Lineal	Lineal	Lineal	Lineal	Lineal	Lineal		No lineal

Tabla 4.15. Comparación de criterios con asignación de valores

Criterio/Modelo	Método cualitativos	Series de Tiempo	Promedios Móviles	Ajuste Exponencial	Regresión lineal	Modelos causales	Análisis de regresiones	Redes Neuronales
<b>Costo</b>	1	3	3	1		3		2
<b>Precisión</b>	1	2	2	2	2		3	3
<b>Datos Disponibles</b>	1	1	2	3	1		1	1
<b>Tiempo</b>	1	3	3	3	1	1		3
<b>Amortiguación de ruidos</b>	0	0	0	0	0	0	0	1
<b>Patrón de datos</b>		4	2	1	1		0	4
<b>Tipo de modelo</b>	0	0	0	0	0	0	0	1
<b>Total Puntaje</b>	<b>4</b>	<b>13</b>	<b>12</b>	<b>10</b>	<b>5</b>	<b>4</b>	<b>4</b>	<b>15</b>

Tabla 4.16. Comparación de criterios con asignación de puntajes

## 4.8. Evaluación comparativa de redes neuronales para pronóstico

En la actualidad, dependiendo de la arquitectura y del algoritmo de aprendizaje, se tendrá el modelo concreto de red neuronal. Sin embargo, las dos características que sobresalen más son el tipo de aprendizaje y la topología de la red, por tanto en estos dos conceptos se basa la siguiente clasificación, la cual fue originalmente propuesta por [Simpson, *op. cit.*]. Así, en cuanto al tipo de aprendizaje, se clasifican en supervisados, no supervisados, híbridos y de aprendizaje reforzado. Por otra parte, de acuerdo a la topología de la red, se identifican dos grandes grupos de redes, realimentadas y unidireccionales (o no realimentadas).

En el caso de los pronósticos en general, las redes más utilizadas son las supervisadas, y es dentro de esta clasificación que se enfocará nuestra elección de la red más apropiada para resolver el problema planteado en esta tesis.

### 4.8.1. Criterios de comparación

Los primeros criterios optados forman parte del trabajo de una tesis doctoral titulada “Redes Neuronales Aplicadas al análisis de datos” [Montaño02] la cual considera cinco elementos importantes para elegir el tipo de red a utilizar en un problema de pronóstico.

#### - **Convergencia**

Es el proceso de aproximación de los parámetros, pesos de la red, es decir, si los parámetros o pesos del sistema son capaces de realizar una determinada clasificación, el sistema acabará aprendiendo en un número finito de pasos. Cuando se requiere menor cantidad de iteraciones para llegar al nivel de error especificado, suele decirse que la convergencia es rápida.

#### - **Tasa de minimización del error**

Permite medir las diferencias existentes entre la salida esperada de la red contra la salida real después del entrenamiento. Su minimización consiste en ir ajustando de forma iterativa los pesos en proporción a la diferencia existente entre la salida actual de la red y la salida deseada, con el objetivo de reducir el error actual de la red.

#### - **Complejidad de la red**

Permite medir la cantidad del número de capas implementados y el manejo de multitud de variables de entrada que repercuten en el incremento del tiempo de procesamiento y el peligro de sobre ajuste, lo que conduce a un pobre desempeño en la predicción fuera de muestra. Pero a la vez la densidad de conexiones en una red neuronal determina su habilidad para almacenar información. Si una red no tiene suficientes conexiones entre nodos, el algoritmo de entrenamiento puede no converger nunca; la red neuronal no es capaz de aproximar la función. Por el otro lado, en una red densamente conectada, puede ocurrir el sobreajuste (overfitting).



Una segunda propuesta de consideración de criterios realizada por una tesis de maestría Pronóstico de Demanda por medio de redes neuronales artificiales en la industria de telecomunicaciones [Salazar+05] considera tres criterios más, que son los siguientes:

- **Robustez**

Es la capacidad de recuperación ante posibles fallas. Permite a la red recuperarse ante la presencia de ruido (datos erróneos o incompletos). Las redes neuronales artificiales son capaces de extraer o abstraer las características esenciales de las entradas aprendidas, de esta manera pueden procesar correctamente datos incompletos o distorsionados.

El criterio a continuación propuesto se basa en la observación de ciertas características de distintos tipos de redes utilizados para problemas de pronóstico.

- **Tiempo de entrenamiento**

Es el tiempo requerido para realizar la selección y visualización de las matrices de datos utilizadas, configuración de la arquitectura y de los parámetros de aprendizaje, inicialización o importación de los pesos, y criterios de parada del entrenamiento

#### 4.8.2. Relación de valores y puntaje por criterio

A continuación, se asignará los puntajes a cada criterio definido:

Para el criterio **convergencia** se asigna un puntaje de 5 para el valor alto debido a que es la principal característica con la que debe contar la red para realizar un buen pronóstico, y un puntaje de 2 para el valor bajo porque de todas maneras contar con esta característica es importante para la red.

Para el criterio **tasa de minimización del error** se asigna un puntaje de 4 al valor alto debido a que el error generado por la red tiene que ser lo mínimo posible para que la red este bien entrenada, y un puntaje de 2 al valor bajo porque aun si la tasa fuera alta tiende a minimizar el error.

Para el criterio de **complejidad de la red** se asigna un puntaje de 3 al valor menor porque se pretende encontrar un red sencilla y clara para el resolución del problema, y un puntaje de 1 al valor mayor porque se pretende utilizar una red lo menos compleja posible.

Para el criterio **robustez** se asigna un puntaje de 3 al valor mayor y de 1 al valor menor porque se pretende elegir la red que tenga una mayor tolerancia a fallos. Para el criterio tiempo de entrenamiento se le asigna un puntaje de 3 al valor alto y un puntaje de 1 al valor bajo debido a que se busca que el tiempo requerido para entrenar la red sea relativamente corto.

En la Tabla 4.17 se lista los valores de cada criterio utilizado para la comparación y se señala los puntajes que corresponden a cada valor.

<b>Criterio</b>	<b>Valores</b>	<b>Descripción</b>	<b>Puntaje</b>
<b>Convergencia</b>	Alta	Los parámetros del modelo tienen una alta capacidad de aproximación.	5
	Baja	Los parámetros del modelo no tienen una alta relación de aproximación entre ellas.	2
<b>Tasa de minimización del error</b>	Alta	El error generado por el tipo de red es mínimo ante los resultados obtenidos.	4
	Baja	El tipo de red halla errores pero no son los más óptimos o que se demora en hacerlo.	2
<b>Complejidad de la red</b>	Menor	La red neuronal es sencilla en la mayoría de las oportunidades y la representación del problema a cargo de la red neuronal es convincente.	3
	Mayor	La red neuronal muchas veces resulta siendo compleja o no representa tan bien el problema planteado.	1
<b>Robustez</b>	Mayor	Mayor tolerancia a fallos o errores producidos por la red neuronal, es capaz de sobreponerse ante alguna eventualidad.	3
	Menor	Menor tolerancia a fallos, la red es frágil ante alguna eventualidad.	1
<b>Tiempo de Entrenamiento</b>	Bajo	El tiempo requerido para entrenar la red es relativamente corto.	3
	Alto	El tiempo requerido para entrenar la red no es tan baja, presenta algunas demoras.	1

Tabla 4.17. Valores y puntaje por criterios de comparación de RNAs

#### 4.8.3. Cuadro comparativo

Para asignar los valores, según los criterios establecidos, se ha revisado los atributos y características de los modelos presentados. Por lo analizado se observa que la red backpropagation es la más ideal para la resolución de nuestro problema.

Las redes que se compararán en la Tabla 4.18 son aquellas que fueron mencionadas en el capítulo anterior con sus respectivas características [Parisi02].

Criterio/Modelo	Perceptrón multicapa (Back Propagation)	Red de Elman (Back Propagation)	RBF (Back Propagation)	Red de Jordan (Back Propagation)
Convergencia	Alta	Alta	Alta	Alta
Minimización del error	Alta	Alta	Alta	Alta
Complejidad de la red	Mayor	Menor	Mayor	Menor
Robustez	Menor	Mayor	Mayor	
Tiempo de entrenamiento	Bajo	Alto	Bajo	Alto

Tabla 4.18. Comparación de criterios con asignación de valores

Criterio/Modelo	Perceptrón multicapa (Back Propagation)	Red de Elman (Retro-propagación)	RBF (Retro-propagación)	Red de Jordan (Retro-propagación)
Convergencia	5	5	5	5
Minimización del error	4	4	4	4
Complejidad de la red	3	1	1	1
Robustez	3	3	3	
Tiempo de entrenamiento	1	1	2	1
<b>Total</b>	<b>16</b>	<b>14</b>	<b>15</b>	<b>11</b>

Tabla 4.19. Comparación de criterios con asignación de puntajes

# Capítulo 5

## Diseño de la RNA para el pronóstico

En este capítulo daremos a conocer el diseño de la arquitectura de red recomendable para nuestro problema tratado, el mismo que comprende la creación y validación de la red neuronal artificial de predicción de la demanda de productos farmacéuticos. Se mostrarán las razones de selección de la topología de la red neuronal como modelo de pronóstico y el tipo de red neuronal más adecuado para resolver nuestro problema. También se expondrán las herramientas necesarias que nos serán de utilidad para la elaboración de la red neuronal.

### 5.1. Flujo de procesos

El siguiente esquema, Figura 5.1, muestra los pasos seguidos para la elaboración del sistema propuesto, del cual se mostrará el desarrollo del primer paso en este capítulo y lo restante será desarrollado en el siguiente capítulo que hace referencia a la implementación del sistema de pronóstico.

Este esquema es un flujo de procesos para pronósticos usando Redes Neuronales, en el capítulo 3 se mostró un esquema con pasos utilizados para problemas de métodos estadísticos, por tanto dicho flujo no puede ser utilizado en esta tesis.

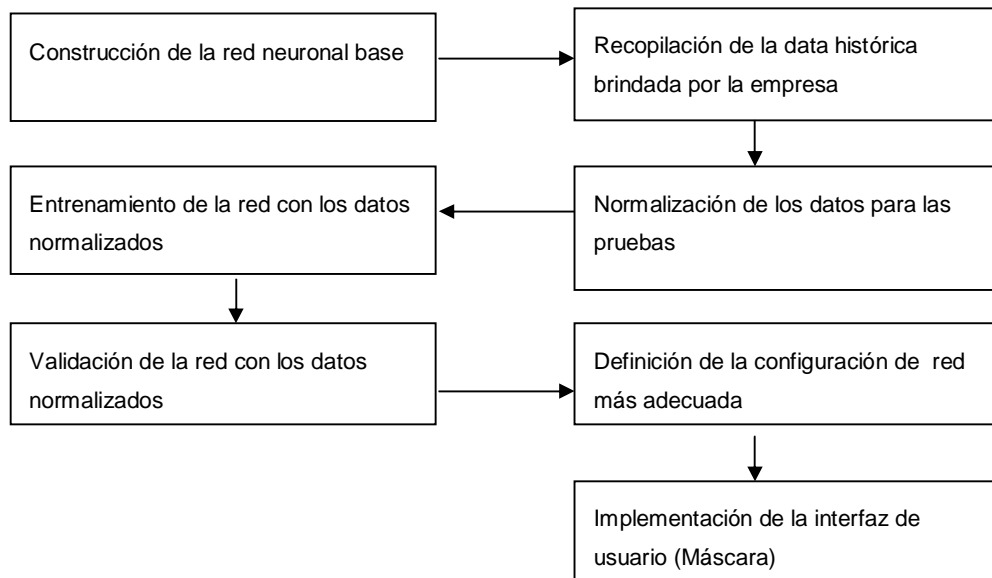


Figura 5.1. Flujo de procesos propuesto para la resolución del problema basado en el Esquema del proceso de la demanda [Cox+02]

## 5.2. Construcción de la red neuronal base

La construcción de la red neuronal base se determinará a partir de los parámetros de entrada y salida de la red que corresponden a las variables influyentes en el pronóstico de la demanda y la cantidad demanda del producto farmacéutico, la topología de la red será obtenida mediante procesos de prueba y error para hallar los valores más adecuados del número de capas ocultas, tipo de red, número de neuronas por cada capa, etc.

Se definirán los productos a pronosticar, las variables de entrada y salida y los valores de cada parámetro de la topología de red más adecuada para resolver el problema.

### 5.2.1. Descripción de los productos:

En esta tesis se pronosticará la demanda de 3 productos farmacéuticos OTC (Over the counter – venta libre) con las que cuenta la empresa FARMOTC ya que poseen demandas variables. Sólo será evaluada la demanda de Lima Metropolitana y Callao teniendo en cuenta que la empresa distribuye 11 productos de esta naturaleza.

Los productos que se va a pronosticar son artículos exclusivos (marcas patentadas) de la distribuidora, es decir, es el único distribuidor de dichos productos en el Perú, por lo tanto la demanda de estos productos no tiene competencia por sobre otra, queda claro entonces que el producto es de exclusividad sin dejar de mencionar que la venta de otros productos similares (productos genéricos) distribuidos por otras empresas sí afecta en su demanda. La denotación y descripción de los productos se menciona a continuación en la Tabla 5.1.

<i>Producto</i>	<i>Descripción</i>
<b>DF</b>	Controla y alivia la diarrea aguda o crónica.
<b>RG</b>	Para la congestión nasal.
<b>CH</b>	Para dolores musculares, golpes, torceduras.

*Tabla 5.1. Descripción de los productos a pronosticar*

*En esta tesis se mostrará el caso de pronóstico para el producto DF.*

### 5.2.2. Definición de las variables de entrada

Para obtener una red que pronostique correctamente se deben de elegir cuidadosamente las variables a emplear, de lo que se trata es incluir en el modelo las variables predictoras que realmente pronostiquen la variable dependiente. La introducción de variables irrelevantes puede provocar un sobreajuste innecesario en el modelo [Palmer+05]. Este caso aparece cuando el número de parámetros o pesos de la red resulta excesivo en relación al problema a tratar y al número de patrones de entrenamiento disponible. Teniendo en cuenta lo comentado anteriormente, se seleccionó un conjunto de variables que permitirán evaluar diferentes aspectos influyentes en el pronóstico de la demanda de productos farmacéuticos.

En el anexo E, se detalla la explicación de las variables seleccionadas indicadas por el experto. Las variables de entrada son los parámetros que afectan al desempeño de la red que se muestran en la Tabla 5.2.

<i>Variable</i>	<i>Descripción</i>	<i>Tipo</i>	<i>Codificación</i>
<b>M</b>	Mes	<i>Enero</i>	<i>1</i>
		<i>Febrero</i>	<i>2</i>
		<i>Marzo</i>	<i>3</i>
		<i>Abril</i>	<i>4</i>
		<i>Mayo</i>	<i>5</i>
		<i>Junio</i>	<i>6</i>
		<i>Julio</i>	<i>7</i>
		<i>Agosto</i>	<i>8</i>
		<i>Septiembre</i>	<i>9</i>
		<i>Octubre</i>	<i>10</i>
		<i>Noviembre</i>	<i>11</i>
		<i>Diciembre</i>	<i>12</i>
<b>PP</b>	Precio del producto	<i>Soles</i>	<i>Precio en S/.</i>
<b>P</b>	Promoción	<i>Agresiva</i>	<i>2</i>
		<i>Moderada</i>	<i>1</i>
		<i>No hay</i>	<i>0</i>
<b>TP</b>	Tiempo de la promoción	<i>N.º de días</i>	<i>(1-7) días</i>
<b>PU</b>	Publicidad	<i>Si hubo</i>	<i>1</i>
		<i>No hay</i>	<i>0</i>
<b>PPC</b>	Precio del producto competencia	<i>Soles</i>	<i>Precio en S/.</i>
<b>PC</b>	Promoción del producto competencia	<i>Agresiva</i>	<i>2</i>
		<i>Moderada</i>	<i>1</i>
		<i>No hay</i>	<i>0</i>
<b>TPC</b>	Tiempo de la promoción del producto competencia	<i>N.º de días</i>	<i>(1-7) días</i>
<b>PUC</b>	Publicidad del producto competencia	<i>Si hubo</i>	<i>1</i>
		<i>No hay</i>	<i>0</i>

Tabla 5.2. Definición de variables de entrada del modelo

### 5.2.3. Definición de las variables de salida

Nuestro propósito es pronosticar la cantidad demandada de un determinado producto farmacéutico OTC de manera mensual, por lo cual nuestro problema consta de variables de salida equivalentes a la cantidad de productos farmacéuticos que se venderá en dicho mes.

La variable de salida es la cantidad demandada en un respectivo mes del producto elegido, es así que la cantidad hallada representa el total de artículos que se deberá pedir al proveedor.

$$Y_i = \text{Cantidad Pronosticada del Producto } i$$

Tenemos tres productos farmacéuticos de los cuales se desea hallar sus respectivas demandas, se mostrará los pasos para pronosticar cada de una de ellas aunque los pasos serán más detallados para el primer producto puesto que la forma de hallar el pronóstico de la demanda de los dos productos restantes es de manera similar.

Para nuestro estudio, se tendrá una salida por cada red neuronal implementada, cada una corresponde a los productos referenciados en la Tabla 5.1.

### 5.2.4. Topología de la red

El tipo de red neuronal que se va a utilizar es un *perceptrón multicapa*, el cual es justificado en la Tabla 4.19. El diseño que se muestra en la Figura 5.2. está elaborado en MATLAB. La red neuronal consta de cinco capas (1 de entrada, 3 ocultas y 1 de salida), la capa de entrada está compuesta por 9 neuronas que representa la cantidad de variables de entrada, las 3 capas ocultas constan de 5 neuronas y la capa de salida con una neurona, que representa el resultado del sistema. Esta configuración ha sido obtenida mediante las pruebas realizadas tal y como se muestra en la sección 6.5 y en el Anexo C. La Figura 5.2. muestra el diseño de la red




Figura 5.2. Esquema del diseño de la red neuronal

La topología de la red propuesta posee las siguientes características:

- **Tipo de red:** Red multicapa unidireccional o perceptrón multicapa (MPL), es decir una red con conexiones que pasan las salidas en una única dirección a neuronas de la siguiente capa.

- **Número de neuronas en la capa de entrada:** 9, valor considerado de acuerdo a las variables de entrada determinadas en la sección 5.2.1.
- **Número de capas ocultas:** 3, valor determinado por prueba y error.
- **Número de neuronas en la capa oculta:** 5. valor hallado mediante las pruebas en el entrenamiento de la red que se muestra en el siguiente capítulo de la tesis.
- **Número de neuronas en la capa de Salida:** 1, valor establecido de acuerdo a las variables de salida explicadas en la sección 5.2.2.
- **Algoritmo de aprendizaje y validación:** Backpropagation.

En la Figura 5.3 se representa el modelo de perceptrón multicapa que se utilizará para el pronóstico de los productos descritos en la Tabla 5.1. donde se muestran las variables de entrada (M, PP, P, TP, PU, PPC, PC, TPC, PUC) descritos en la Tabla 5.2., El número de capas ocultas y la cantidad neuronas por cada capa oculta descritos anteriormente y la salida  $Y$  que representa la cantidad demandada del producto farmacéutico pronosticada por la red neuronal que corresponde a la variable  $Y_i$  (variable de salida) que es la cantidad pronosticada del producto  $i$ , con  $i=1,2,3$ .

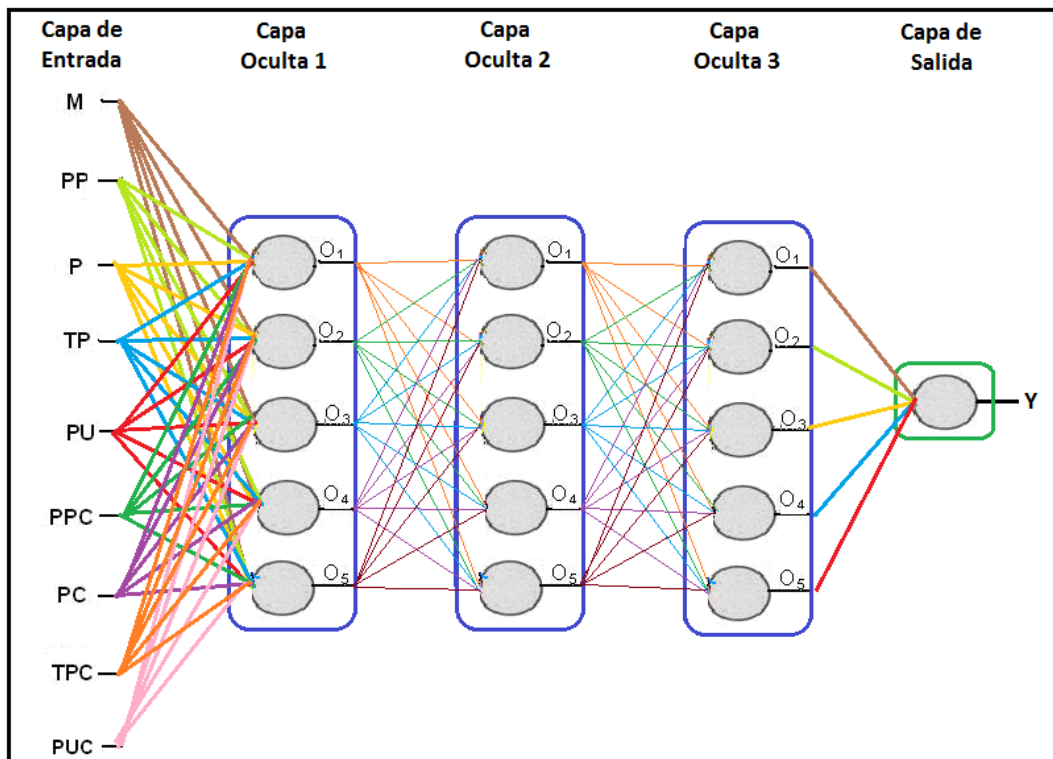


Figura 5.3. Arquitectura de la red neuronal para cada producto



# Capítulo 6

## Sistema de pronóstico

En este capítulo se dará a conocer el desarrollo del software ideado para la solución del problema tratado en este trabajo. Se mostrarán los requerimientos mínimos de hardware y software para su correcto funcionamiento, la recopilación de los datos históricos para obtener la información sobre las variables de entrada, las instancias de prueba, la validación de la red más adecuada y la implementación de la máscara del software realizado con el IDE NetBeans 6.5 y la herramienta MATLAB 9.0.

### 6.1. Configuración

#### 6.1.1. Requerimientos de Hardware y Software para pruebas

- **Hardware Usado:** Se utilizó una computadora de 1 GB de Memoria RAM, 2.8 GHz de Procesador y 250 GB de disco duro.
- **Software Usado:** Herramienta MATLAB 9.0, entorno Java (IDE Netbeans 6.5), jdk 6.0, Librería JmatLink 3.0 (jMatLink.dll).
- **Sistema Operativo:** Windows XP Professional SP3.

#### 6.1.2. Requerimientos mínimos de Hardware y Software para funcionamiento

- **Hardware:** Computadora de 256 de Memoria RAM, 1.6 GHz de Procesador, 20 GB de disco duro.
- **Software:** Herramienta MATLAB 9.0, entorno Java (IDE Netbeans 6.5), jdk 5.0, Librería JmatLink 3.0 (jMatLink.dll).
- **Sistema Operativo:** Windows XP Professional SP2.

### 6.2. Instancias de pruebas

La Tabla 6.1. muestra los datos obtenidos concernientes a las variables mencionadas en la Tabla 5.2. correspondientes al **producto DF** para cada mes de los años 2006, 2007, 2008, 2009 y el primer trimestre del año 2010 brindados por la empresa FARMOTC, de este conjunto seleccionamos los datos de los años 2006, 2007, 2008 y el primer trimestre del año 2009 para la fase de entrenamiento y para la fase de validación de los meses restantes del año 2009 y del primer trimestre del 2010. Los datos obtenidos para los otros dos productos RG y CH se muestran en el Anexo D.

La variable PP que corresponde al **Precio** es por cada caja del Producto (unidades con las que opera la distribuidora) que ha sido obtenido a partir de los registros históricos de la empresa, el resto de variables de entrada han sido estimadas por el experto encargado de la actividad de pronóstico, dichas variables juegan un papel

importante para la variación de la demanda por lo que su experiencia ha sido útil en la obtención de la data histórica de las variables restantes.

$i$	$M_i$	$PP_i$	$P_i$	$TP_i$	$PU_i$	$PPC_i$	$PC_i$	$TPC_i$	$PUC_i$	$Y_i$	
2006	1	1	53,83	2	4	1	30,82	0	0	0	6.143
	2	2	54,80	0	0	0	32,51	0	0	0	5.857
	3	3	55,17	1	7	1	35,26	1	1	0	6.084
	4	4	60,55	0	0	1	30,28	0	0	0	1.790
	5	5	58,86	0	0	0	39,15	1	2	1	2.761
	6	6	63,32	0	0	0	37,17	0	0	0	3.641
	7	7	59,84	0	0	1	41,26	0	0	0	3.886
	8	8	60,96	1	3	1	31,02	1	3	1	2.972
	9	9	60,41	0	0	0	36,84	0	0	1	3.420
	10	10	61,25	0	0	1	30,25	1	4	0	3.184
	11	11	60,52	0	0	0	34,12	2	5	1	3.932
	12	12	60,48	2	5	0	38,25	0	0	1	3.598
2007	13	1	62,96	1	4	1	40,20	0	0	0	5.059
	14	2	63,17	0	0	0	40,86	0	0	0	4.863
	15	3	62,33	1	7	1	43,15	0	0	0	6.139
	16	4	62,73	0	0	0	39,72	0	0	1	3.644
	17	5	62,47	0	0	1	38,17	0	0	1	4.951
	18	6	64,83	0	0	0	43,02	2	4	1	2.853
	19	7	65,90	0	0	1	42,16	0	0	1	2.025
	20	8	65,79	0	0	0	39,96	0	0	0	4.225
	21	9	68,95	0	0	0	41,25	2	3	1	1.518
	22	10	69,05	0	0	1	43,25	1	6	1	3.266
	23	11	80,36	1	5	0	40,12	0	0	0	4.033
	24	12	80,60	2	6	1	43,12	0	0	0	3.209
2008	25	1	70,71	0	0	1	41,25	2	3	1	4.800
	26	2	68,79	1	4	0	42,14	2	2	1	4.454
	27	3	69,77	2	5	0	39,26	0	0	0	4.991
	28	4	69,56	1	7	0	42,13	1	3	1	4.077
	29	5	69,84	0	0	0	41,25	0	0	0	3.579
	30	6	70,27	0	0	1	41,68	1	1	0	3.950
	31	7	69,94	0	0	1	39,26	0	0	0	3.544
	32	8	70,21	2	2	0	39,17	0	0	0	2.986
	33	9	69,96	0	0	0	40,13	0	0	0	3.636
	34	10	69,81	0	0	1	38,13	0	0	1	2.730
	35	11	70,56	0	0	0	36,48	0	0	1	3.285
	36	12	70,15	1	5	0	39,13	0	0	0	3.130
2009	37	1	70,72	1	6	1	42,15	0	0	1	5.520
	38	2	70,43	2	6	1	39,15	0	0	0	6.163
	39	3	73,18	0	0	0	43,34	2	5	1	2.664
	40	4	75,25	0	0	0	40,45	2	6	1	2.885
	41	5	74,78	0	0	0	41,09	2	4	1	2.423
	42	6	75,75	1	3	1	41,78	1	5	0	3.772
	43	7	75,39	1	2	1	41,65	1	6	0	3.534
	44	8	75,42	1	2	1	41,46	1	3	1	3.487
	45	9	74,88	0	0	0	42,09	1	7	1	2.698
	46	10	74,30	0	0	0	42,36	2	5	1	2.520
	47	11	75,67	2	2	1	42,00	1	7	0	3.803
	48	12	78,77	1	1	0	42,87	2	7	1	2.012
2010	49	1	79,53	2	5	1	43,78	0	0	0	4.051
	50	2	79,26	1	6	1	43,96	0	0	0	4.194
	51	3	78,46	2	3	1	44,17	0	0	0	5.135

Datos para la fase de entrenamiento

Datos para la fase de validación

Tabla 6.1. Datos totales para el entrenamiento y validación

**6.2.1. Instancias de pruebas para el entrenamiento**

Como se mencionó en la sección anterior los datos para el entrenamiento de la red neuronal equivalen aproximadamente a los 3/4 del total de datos obtenidos que comprenden los registros del número 1 al 39 referenciado en la Tabla 6.1.

Esta cantidad de datos con la que cuenta la muestra (39) es prudente para la realización del entrenamiento de la red puesto que muestra una variedad en los datos que será útil para evitar el sobre ajuste o memorización de los mismos.

	i	M <sub>i</sub>	PP <sub>i</sub>	P <sub>i</sub>	TP <sub>i</sub>	PU <sub>i</sub>	PPC <sub>i</sub>	PC <sub>i</sub>	TPC <sub>i</sub>	PUC <sub>i</sub>	Y <sub>i</sub>
2006	1	1	53,83	2	4	1	30,82	0	0	0	6.143
	2	2	54,80	0	0	0	32,51	0	0	0	5.857
	3	3	55,17	1	7	1	35,26	1	1	0	6.084
	4	4	60,55	0	0	1	30,28	0	0	0	1.790
	5	5	58,86	0	0	0	39,15	1	2	1	2.761
	6	6	63,32	0	0	0	37,17	0	0	0	3.641
	7	7	59,84	0	0	1	41,26	0	0	0	3.886
	8	8	60,96	1	3	1	31,02	1	3	1	2.972
	9	9	60,41	0	0	0	36,84	0	0	1	3.420
	10	10	61,25	0	0	1	30,25	1	4	0	3.184
	11	11	60,52	0	0	0	34,12	2	5	1	3.932
	12	12	60,48	2	5	0	38,25	0	0	1	3.598
2007	13	1	62,96	1	4	1	40,20	0	0	0	5.059
	14	2	63,17	0	0	0	40,86	0	0	0	4.863
	15	3	62,33	1	7	1	43,15	0	0	0	6.139
	16	4	62,73	0	0	0	39,72	0	0	1	3.644
	17	5	62,47	0	0	1	38,17	0	0	1	4.951
	18	6	64,83	0	0	0	43,02	2	4	1	2.853
	19	7	65,90	0	0	1	42,16	0	0	1	2.025
	20	8	65,79	0	0	0	39,96	0	0	0	4.225
	21	9	68,95	0	0	0	41,25	2	3	1	1.518
	22	10	69,05	0	0	1	43,25	1	6	1	3.266
	23	11	80,36	1	5	0	40,12	0	0	0	4.033
	24	12	80,60	2	6	1	43,12	0	0	0	3.209
2008	25	1	70,71	0	0	1	41,25	2	3	1	4.800
	26	2	68,79	1	4	0	42,14	2	2	1	4.454
	27	3	69,77	2	5	0	39,26	0	0	0	4.991
	28	4	69,56	1	7	0	42,13	1	3	1	4.077
	29	5	69,84	0	0	0	41,25	0	0	0	3.579
	30	6	70,27	0	0	1	41,68	1	1	0	3.950
	31	7	69,94	0	0	1	39,26	0	0	0	3.544
	32	8	70,21	2	2	0	39,17	0	0	0	2.986
	33	9	69,96	0	0	0	40,13	0	0	0	3.636
	34	10	69,81	0	0	1	38,13	0	0	1	2.730
	35	11	70,56	0	0	0	36,48	0	0	1	3.285
	36	12	70,15	1	5	0	39,13	0	0	0	3.130
2009	37	1	70,72	1	6	1	42,15	0	0	1	5.520
	38	2	70,43	2	6	1	39,15	0	0	0	6.163
	39	3	73,18	0	0	0	43,34	2	5	1	2.664

Tabla 6.2. Datos para la fase de entrenamiento

En la Tabla 6.2 se muestra los datos que corresponden a la fase de entrenamiento, donde  $i$  es la cantidad de datos de la muestra. A continuación, se describirá un ejemplo para detallar claramente los valores que toma cada variable de entrada para un determinado registro en el tiempo (mensualmente).

**Ejemplo:**

Para el conjunto de datos del registro  $i=1$  se tiene:

- $M=1$ , indica que el mes de pronóstico es Enero.
- $PP=53.83$ , indica que el precio del producto fue 53.83 nuevos soles (por caja).
- $P=2$ , indica que la promoción fue agresiva.
- $TP=4$ , indica que el tiempo de publicidad fue de 4 días.
- $PU=1$ , indica que hubo publicidad ese mes.
- $PPC=30.82$ , indica que el precio del producto de la competencia fue 30.82 nuevos soles (por caja).
- $PC=0$ , indica que el producto de la competencia no tuvo promoción
- $TPC=0$ , indica que el tiempo de promoción de la competencia fue cero debido a que no tuvo promoción.
- $PUC=0$ ; indica que el producto de la competencia no tuvo publicidad.

**6.2.2. Instancias de prueba para la validación**

Los datos para la fase de validación de la red neuronal equivalen aproximadamente a un cuarto (1/4) del total de datos obtenidos que comprenden los registros del 40 al 51 de la Tabla 6.1.

Esta cantidad de datos con la que cuenta la muestra (12) es razonable para la validación de la red puesto que muestra una variedad en los datos los mismos que serán útiles para determinar si la red seleccionada generaliza adecuadamente.

$i$	$M_i$	$PP_i$	$P_i$	$TP_i$	$PU_i$	$PPC_i$	$PC_i$	$TPC_i$	$PUC_i$	$Y_i$
40	4	75,25	0	0	0	40,45	2	6	1	2.885
41	5	74,78	0	0	0	41,09	2	4	1	2.423
42	6	75,75	1	3	1	41,78	1	5	0	3.772
43	7	75,39	1	2	1	41,65	1	6	0	3.534
44	8	75,42	1	2	1	41,46	1	3	1	3.487
45	9	74,88	0	0	0	42,09	1	7	1	2.698
46	10	74,30	0	0	0	42,36	2	5	1	2.520
47	11	75,67	2	2	1	42,00	1	7	0	3.803
48	12	78,77	1	1	0	42,87	2	7	1	2.012
49	1	79,53	2	5	1	43,78	0	0	0	4.051
50	2	79,26	1	6	1	43,96	0	0	0	4.194
51	3	78,46	2	3	1	44,17	0	0	0	5.135

Figura 6.3. Datos para la fase de validación

En la Tabla 6.3 se muestra los datos correspondientes a la validación, donde  $i$  es la cantidad de datos de la muestra y los valores indicados conciernen a las variables de entrada indicadas en la Tabla 5.2. La explicación de cada variable es similar al ejemplo mostrado en la sección anterior.

### 6.3. Normalización de datos

El proceso de normalización es necesaria para nuestro trabajo puesto que se desea uniformizar los datos ya que las unidades de cada variable son disímiles (por ejemplo las unidades de los precios son demasiado altas a comparación de las unidades del resto de variables) y se diferencian de manera notable. Con este proceso de normalización se pretende obtener valores uniformes de entrada en un rango de 0-1 para que no existan dependencias de ninguna variable para la obtención del resultado ya que cada una de ellas influye en el pronóstico de manera análoga.

Este proceso se ha llevado a cabo a partir de la división de todos los datos de una variable entre el mayor de los mismos tal y como se muestra en la siguiente ecuación:

$$D_n = D_i / MD$$

- $D_n$  = Dato Normalizado
- $D_i$  = Dato  $i$  de la variable de entrada
- $MD$  = Máximo valor de la variable de entrada

A continuación, se muestran dos ejemplos de normalización para explicar de manera clara este proceso.

#### *Ejemplo 1*

- **Normalizando la variable M** (Mes)

$MD=12$ : Representa el mayor valor de la variable M de los datos de toda la muestra de la Tabla 6.2.

$D_1=1$ : Representa el valor a normalizar, que corresponde al mes de Enero.

$D_n=1/12= 0.08$ : Resultado de la normalización.

El valor normalizado para la variable M y el dato 1 es 0.08

#### *Ejemplo 2*

- **Normalizando la variable PP** (Precio del producto)

$MD=80.60$ : Representa el mayor valor de la variable PP de los datos de toda la muestra de la Tabla 6.2.

$D_1=53.83$ : Representa el valor a normalizar.

$D_n=53.83/80.60= 0.67$ : Resultado de la normalización.

El valor normalizado para la variable PP y el dato 1 es 0.6

La normalización de los datos de entrada se lleva a cabo de forma similar para el resto de variables de los datos de entrenamiento y validación, en la Tabla 6.4 y 6.5 se muestran los resultados del proceso de normalización.

i	M <sub>i</sub>	PP <sub>i</sub>	P <sub>i</sub>	TP <sub>i</sub>	PU <sub>i</sub>	PPC <sub>i</sub>	PC <sub>i</sub>	TPC <sub>i</sub>	PUC <sub>i</sub>	Y <sub>i</sub>
1	0,0833	0,6678	1,0	0,5714	1	0,6978	0,0	0,0000	0	0,9968
2	0,1667	0,6799	0,0	0,0000	0	0,7360	0,0	0,0000	0	0,9503
3	0,2500	0,6845	0,5	1,0000	1	0,7983	0,5	0,1429	0	0,9872
4	0,3333	0,7513	0,0	0,0000	1	0,6855	0,0	0,0000	0	0,2904
5	0,4167	0,7302	0,0	0,0000	0	0,8863	0,5	0,2857	1	0,4480
6	0,5000	0,7856	0,0	0,0000	0	0,8415	0,0	0,0000	0	0,5908
7	0,5833	0,7424	0,0	0,0000	1	0,9341	0,0	0,0000	0	0,6305
8	0,6667	0,7563	0,5	0,4286	1	0,7023	0,5	0,4286	1	0,4822
9	0,7500	0,7495	0,0	0,0000	0	0,8341	0,0	0,0000	1	0,5549
10	0,8333	0,7599	0,0	0,0000	1	0,6849	0,5	0,5714	0	0,5166
11	0,9167	0,7508	0,0	0,0000	0	0,7725	1,0	0,7143	1	0,6380
12	1,0000	0,7504	1,0	0,7143	0	0,8660	0,0	0,0000	1	0,5838
13	0,0833	0,7811	0,5	0,5714	1	0,9101	0,0	0,0000	0	0,8209
14	0,1667	0,7837	0,0	0,0000	0	0,9251	0,0	0,0000	0	0,7891
15	0,2500	0,7733	0,5	1,0000	1	0,9769	0,0	0,0000	0	0,9961
16	0,3333	0,7783	0,0	0,0000	0	0,8993	0,0	0,0000	1	0,5913
17	0,4167	0,7751	0,0	0,0000	1	0,8641	0,0	0,0000	1	0,8033
18	0,5000	0,8043	0,0	0,0000	0	0,9739	1,0	0,5714	1	0,4629
19	0,5833	0,8176	0,0	0,0000	1	0,9545	0,0	0,0000	1	0,3286
20	0,6667	0,8162	0,0	0,0000	0	0,9048	0,0	0,0000	0	0,6855
21	0,7500	0,8554	0,0	0,0000	0	0,9339	1,0	0,4286	1	0,2463
22	0,8333	0,8567	0,0	0,0000	1	0,9792	0,5	0,8571	1	0,5299
23	0,9167	0,9970	0,5	0,7143	0	0,9083	0,0	0,0000	0	0,6544
24	1,0000	1,0000	1,0	0,8571	1	0,9762	0,0	0,0000	0	0,5207
25	0,0833	0,8772	0,0	0,0000	1	0,9339	1,0	0,4286	1	0,7788
26	0,1667	0,8534	0,5	0,5714	0	0,9540	1,0	0,2857	1	0,7227
27	0,2500	0,8656	1,0	0,7143	0	0,8887	0,0	0,0000	0	0,8098
28	0,3333	0,8629	0,5	1,0000	0	0,9538	0,5	0,4286	1	0,6615
29	0,4167	0,8664	0,0	0,0000	0	0,9339	0,0	0,0000	0	0,5807
30	0,5000	0,8718	0,0	0,0000	1	0,9436	0,5	0,1429	0	0,6409
31	0,5833	0,8676	0,0	0,0000	1	0,8888	0,0	0,0000	0	0,5750
32	0,6667	0,8710	1,0	0,2857	0	0,8868	0,0	0,0000	0	0,4845
33	0,7500	0,8679	0,0	0,0000	0	0,9084	0,0	0,0000	0	0,5900
34	0,8333	0,8660	0,0	0,0000	1	0,8632	0,0	0,0000	1	0,4430
35	0,9167	0,8754	0,0	0,0000	0	0,8259	0,0	0,0000	1	0,5330
36	1,0000	0,8703	0,5	0,7143	0	0,8858	0,0	0,0000	0	0,5079
37	0,0833	0,8774	0,5	0,8571	1	0,9543	0,0	0,0000	1	0,8957
38	0,1667	0,8738	1,0	0,8571	1	0,8863	0,0	0,0000	0	1,0000
39	0,2500	0,9079	0,0	0,0000	0	0,9812	1,0	0,7143	1	0,4323

Tabla 6.4. Datos normalizados para la fase de entrenamiento

i	M <sub>i</sub>	PP <sub>i</sub>	P <sub>i</sub>	TP <sub>i</sub>	PU <sub>i</sub>	PPC <sub>i</sub>	PC <sub>i</sub>	TPC <sub>i</sub>	PUC <sub>i</sub>	Y <sub>i</sub>
40	0,3333	0,9336	0,0	0,0000	0	0,9158	1,0	0,8571	1	0,4681
41	0,4167	0,9277	0,0	0,0000	0	0,9303	1,0	0,5714	1	0,3932
42	0,5000	0,9398	0,5	0,4286	1	0,9459	0,5	0,7143	0	0,6120
43	0,5833	0,9353	0,5	0,2857	1	0,9429	0,5	0,8571	0	0,5734
44	0,6667	0,9356	0,5	0,2857	1	0,9386	0,5	0,4286	1	0,5658
45	0,7500	0,9290	0,0	0,0000	0	0,9529	0,5	1,0000	1	0,4378
46	0,8333	0,9218	0,0	0,0000	0	0,9590	1,0	0,7143	1	0,4089
47	0,9167	0,9388	1,0	0,2857	1	0,9509	0,5	1,0000	0	0,6171
48	1,0000	0,9772	0,5	0,1429	0	0,9706	1,0	1,0000	1	0,3265
49	0,0833	0,9867	1,0	0,7143	1	0,9912	0,0	0,0000	0	0,6573
50	0,1667	0,9833	0,5	0,8571	1	0,9952	0,0	0,0000	0	0,6805
51	0,2500	0,9734	1,0	0,4286	1	1,0000	0,0	0,0000	0	0,8332

Tabla 6.5. Datos normalizados para la fase de validación

## 6.4. Fase de entrenamiento

La fase de entrenamiento de una red neuronal sirve para asociar un patrón de entradas a un patrón de salidas de tal manera que la red neuronal pueda aprender a pronosticar de forma casi exacta la cantidad demanda de cada producto farmacéutico de acuerdo al correcto mapeo y conocimiento almacenado (configuración de pesos y bias).

El proceso de entrenamiento de las redes neuronales se realizó usando las funciones del Neural NetWork de la Caja de Herramientas del Matlab (estas funciones se describen detalladamente en el Anexo B) con las cuales se diseñaron varias configuraciones que constan de distintos algoritmos de aprendizaje así como variación de parámetros. A continuación se mostrarán las configuraciones de las redes pronosticadoras para los 3 productos correspondientes.

### 6.4.1. Proceso de entrenamiento de la RN del producto DF

#### 6.4.1.1 Configuraciones de las redes

A continuación, se mostrarán 8 redes que fueron creadas y entrenadas cada cual con distintos parámetros en cada fase y se mostrarán sus respectivos errores, los cuales nos servirán para elegir la red más adecuada para el producto DF. Cada configuración define las funciones utilizadas, los parámetros especificados, el esquema de red obtenido, la configuración de los pesos y el performance alcanzado.

##### 6.4.1.1.1 Configuración 1

**PRONOSTICADOR\_1.** Red Neuronal que muestra su configuración en la Figura 6.1. con los diversos parámetros necesarios para su creación.

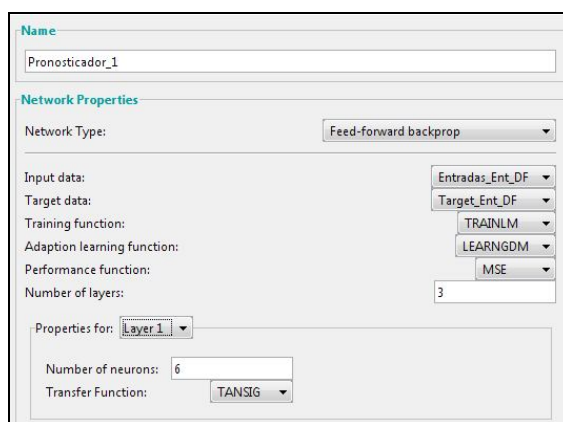


Figura 6.1. Configuración de la red PRONOSTICADOR\_1

- **Método**

El método utilizado se basa en la creación de una red neuronal backpropagation haciendo uso del entorno del MATLAB – TOOLBOXES – NEWRAL NETWORK que provee una herramienta fantástica para la

elaboración de redes neuronales. Esta herramienta cuenta con las funciones específicas para la configuración de cualquier tipo de red.

• **Descripción**

La red neuronal creada muestra la siguiente configuración:

- Tipo de red: backpropagation
- Rango de las entradas: 0 y 1
- Función de Entrenamiento: TRAINLM, función que actualiza los pesos y las ganancias de acuerdo a la optimización de Levenberg-Marquardt.
- Función de Aprendizaje: LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.
- Función de Rendimiento: MSE, Función de rendimiento basado en el error cuadrado medio.
- Numero de capas: 4 ( 1 de entrada, 2 ocultas y 1 de salida) – Capa de entrada reconocida automaticamente por el MATLAB.
- Número de neuronas por capa: La primera capa cuenta con 9 neuronas en la capa de entrada, 6 neuronas en cada capa oculta y una neurona en la capa de salida. Véase la Figura 6.2.




Figura 6.2. Esquema de la red neuronal PRONOSTICADOR\_1

- Propiedades de las capas: ambas capas hacen uso de la función Tansig.
- Función de transferencia sigmoidea tangente e hiperbólica.
- Parámetros: Los parámetros de la red se muestran en la Figura 6.3.

Training Parameters			
show	25	min_grad	1e-010
showWindow	true	mu	0.001
showCommandLine	false	mu_dec	0.1
epochs	1000	mu_inc	10
time	Inf	mu_max	10000000000
goal	0		
max_fail	6		
mem_reduc	1		

Figura 6.3. Configuración de los parámetros solicitados por la red

- Configuración de pesos: Los pesos hallados de la red se muestra en la Figura 6.4.

Network: Pronosticador_1	
Select the weight or bias to view:	iw{1,1} - Weight to layer 1 from input 1
<pre>[-0.029217 0.70259 -0.33019 -0.64647 -0.60626 -0.15438 -0.53516 -0.61549 -0.91683; -0.1272 0.58468 0.87058 -0.39415 -0.65301 -0.62504 -0.18102 -0.75869 -0.47102; -0.12316 0.33401 0.87008 -0.067294 -0.63029 0.93705 0.21963 -0.47057 0.69666; -0.40336 -0.25285 0.10447 -0.56138 -0.13394 0.99929 -0.4953 -0.37748 -0.98061; 0.021195 0.77614 0.30508 0.85767 -0.47054 -0.15227 0.25618 -0.1889 1.0683; 0.025274 0.07702 0.20424 -0.71619 0.9934 -0.91245 0.49559 0.018438 0.54044]</pre>	

Figura 6.4. Configuración de los pesos de la red PRONOSTICADOR\_1



- **Resultado**

El resultado que nos muestra el entrenamiento, Figura 6.5, es el performance o rendimiento que usa la función del error cuadrático medio que es el siguiente:

**Error** → 0.0872

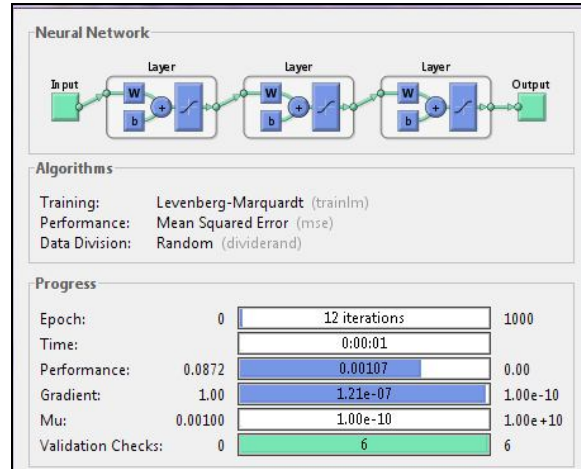


Figura 6.5. Imagen del entrenamiento realizado por la red PRONOSTICADOR\_1

#### 6.4.1.1.2 Configuración 2

**PRONOSTICADOR\_2.** Red Neuronal que muestra su configuración en la Figura 6.6.

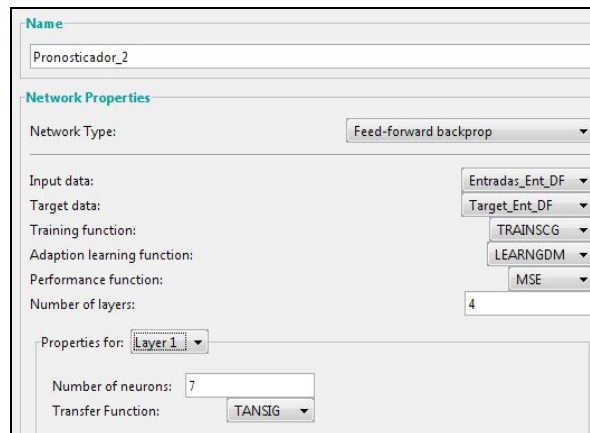


Figura. 6.6. Configuración de la red PRONOSTICADOR\_2

- **Método**

RNA backpropagation creado bajo el entorno del NEWRAL NETWORK.

- **Descripción**

La red neuronal creada muestra la siguiente configuración:

- Tipo de red: backpropagation
- Rango de las entradas: 0 y 1

- Función de Entrenamiento: : TRAINSCG función que actualiza los pesos y valores de los bias de acuerdo al método retropropagación de gradiente conjugado escalado.
- Función de Aprendizaje: LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.
- Función de Rendimiento: MSE, Función de rendimiento basado en el error cuadrado medio.
- Numero de capas: 5 ( 1 de entrada, 3 ocultas y 1 de salida) – Capa de entrada reconocida automaticamente por el MATLAB.
- Número de neuronas por capa: La primera capa cuenta con 9 neuronas en la capa de entrada, 7 neuronas en cada capa oculta y una neurona en la capa de salida. Véase la Figura 6.7.




Figura 6.7. Esquema de la red neuronal PRONOSTICADOR\_2

- Propiedades de las capas: ambas capas hacen uso de la función Tansig.
- Función de transferencia sigmoidea tangente e hiperbólica.
- Parámetros: Los parámetros de la red se muestran en la Figura 6.8.

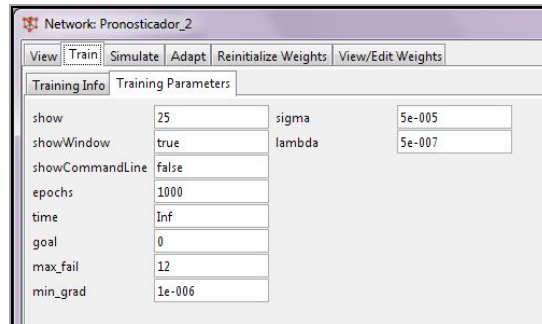


Figura. 6.8. Configuración de los parámetros solicitados por la red PRONOSTICADOR\_2

- Configuración de pesos: Los pesos hallados de la red se muestra en la Figura 6.9.




Figura. 6.9. Configuración de los pesos de la red PRONOSTICADOR\_2

- **Resultado**

El resultado que nos muestra el entrenamiento, Figura 6.10., es el performance o rendimiento que usa la función del error cuadrático medio que es el siguiente:

**Error** → 0.164

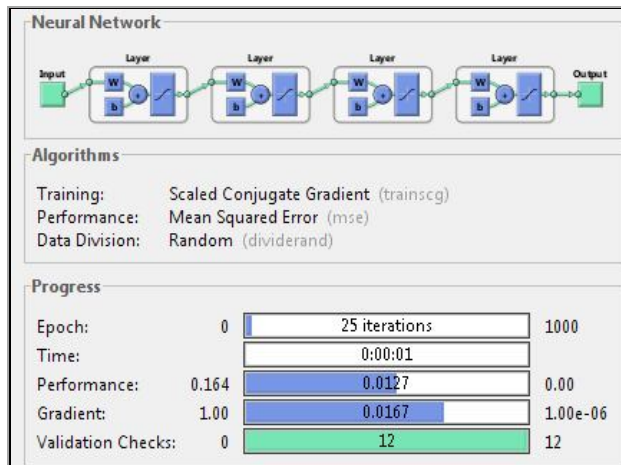


Figura 6.10. Imagen del entrenamiento realizado por la red PRONOSTICADOR\_2

### 6.4.1.1.3. Configuración 3

**PRONOSTICADOR \_3.** Red Neuronal que muestra su configuración en la Figura 6.11.

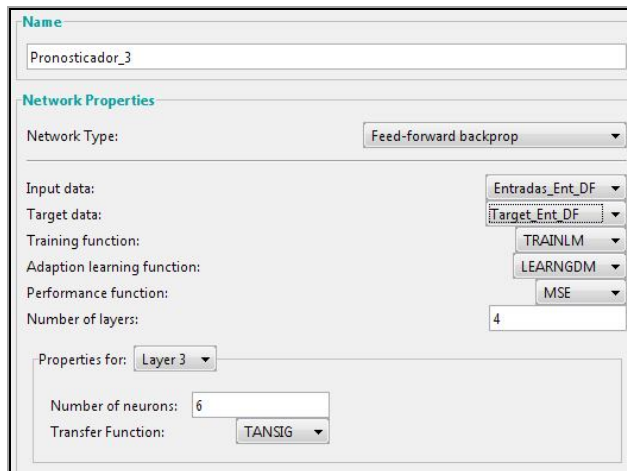


Figura 6.11. Configuración de la red PRONOSTICADOR\_3

- **Método**

RNA backpropagation creado bajo el entorno del NEWRAL NETWORK.

- **Descripción**

La red neuronal creada muestra la siguiente configuración:

- Tipo de red: backpropagation
- Rango de las entradas: 0 y 1

- Función de Entrenamiento: TRAINLM, función que actualiza los pesos y las ganancias de acuerdo a la optimización de Levenberg-Marquardt.
- Función de Aprendizaje: LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.
- Función de Rendimiento: MSE, Función de rendimiento basado en el error cuadrado medio.
- Numero de capas: 5 ( 1 de entrada, 3 ocultas y 1 de salida) – Capa de entrada reconocida automaticamente por el MATLAB.
- Número de neuronas por capa: La primera capa cuenta con 9 neuronas en la capa de entrada, 6 neuronas en cada capa oculta y una neurona en la capa de salida. Véase la Figura 6.12.




Figura 6.12. Esquema de la red neuronal PRONOSTICADOR\_3

- Propiedades de las capas: ambas capas hacen uso de la función Tansig.
- Función de transferencia sigmoidea tangente e hiperbólica.
- Parámetros: Los parámetros de la red se muestran en la Figura 6.13.

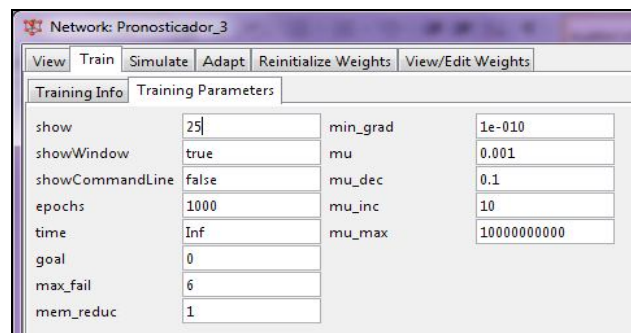


Figura 6.13. Configuración de los parámetros solicitados por la red PRONOSTICADOR\_3

- Configuración de pesos: Los pesos hallados de la red se muestra en la Figura 6.14.

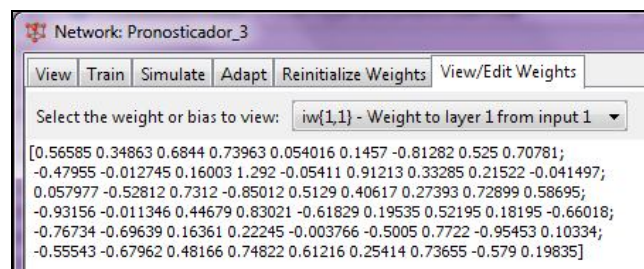


Figura 6.14. Configuración de los pesos de la red PRONOSTICADOR\_3

- **Resultado**

El resultado que nos muestra el entrenamiento, Figura 6.15., es el performance o rendimiento que usa la función del error cuadrático medio que es el siguiente:

**Error** → 0.0277

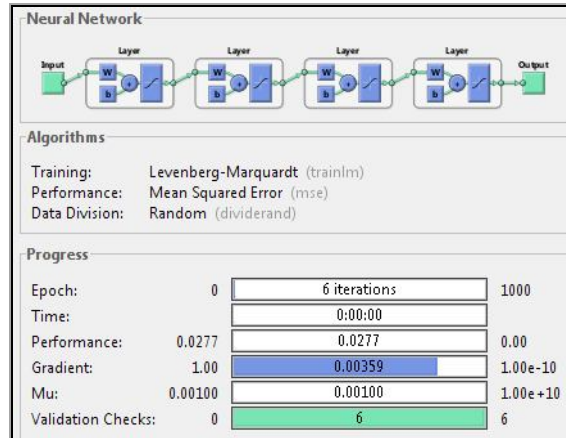


Figura 6.15. Imagen del entrenamiento realizado por la red PRONOSTICADOR\_3

#### 6.4.1.1.4. Configuración 4

**PRONOSTICADOR\_4.** Red Neuronal que muestra su configuración en la Figura 6.16.

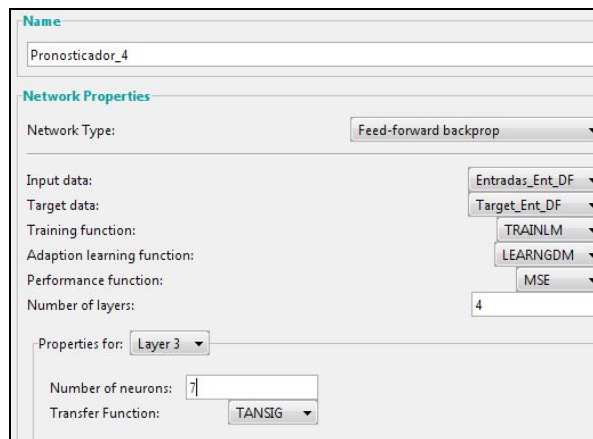


Figura 6.16. Configuración de la red PRONOSTICADOR\_4

- **Método**

RNA backpropagation creado bajo el entorno del NEWRAL NETWORK.

- **Descripción.**

La red neuronal creada muestra la siguiente configuración:

- Tipo de red: backpropagation
- Rango de las entradas: 0 y 1

- Función de Entrenamiento: TRAINLM, función que actualiza los pesos y las ganancias de acuerdo a la optimización de Levenberg-Marquardt.
- Función de Aprendizaje: LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.
- Función de Rendimiento: MSE, Función de rendimiento basado en el error cuadrado medio.
- Numero de capas: : 5 ( 1 de entrada, 3 ocultas y 1 de salida) – Capa de entrada reconocida automaticamente por el MATLAB.
- Número de neuronas por capa: La primera capa cuenta con 9 neuronas en la capa de entrada, 7 neuronas en cada capa oculta y una neurona en la capa de salida. Véase la Figura 6.17.




Figura 6.17. Esquema de la red neuronal PRONOSTICADOR\_4

- Propiedades de las capas: ambas capas hacen uso de la función Tansig.
- Función de transferencia sigmoidea tangente e hiperbólica.
- Parámetros: Los parámetros de la red se muestran en la Figura 6.18.

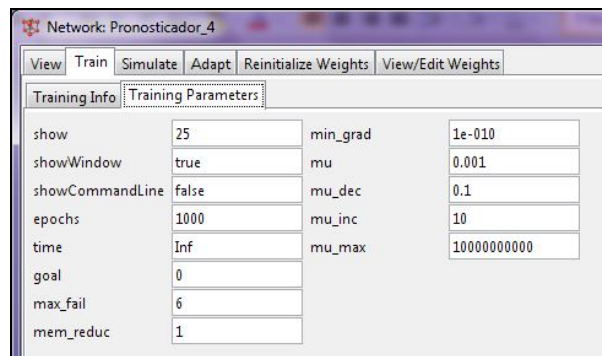


Figura 6.18. Configuración de los parámetros solicitados por la red PRONOSTICADOR\_4

- Configuración de pesos: Los pesos hallados de la red se muestra en la Figura 6.19.

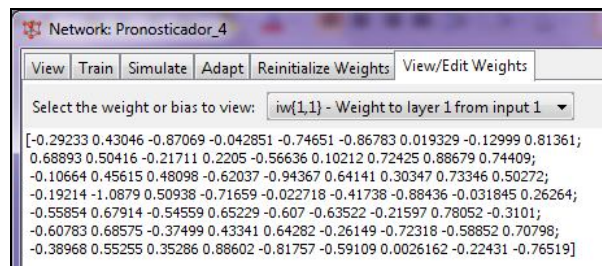


Figura 6.19. Configuración de los pesos de la red PRONOSTICADOR\_4

- **Resultado**

El resultado que nos muestra el entrenamiento, Figura 6.20., es el performance o rendimiento que usa la función del error cuadrático medio que es el siguiente:

**Error** → 0.101

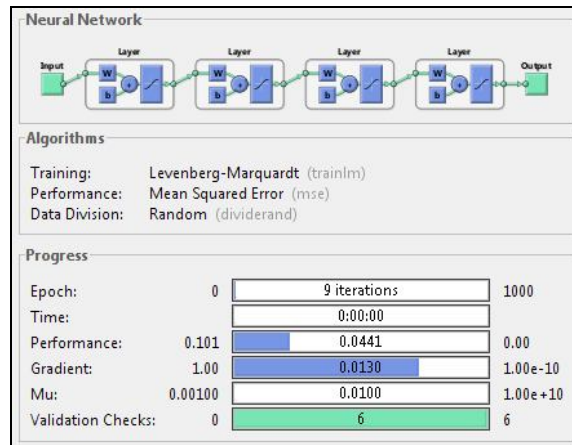


Figura 6.20. Imagen del entrenamiento realizado por la red PRONOSTICADOR\_4

#### 6.4.1.1.5. Configuración 5

**PRONOSTICADOR\_5.** Red Neuronal que muestra su configuración en la Figura 6.21.

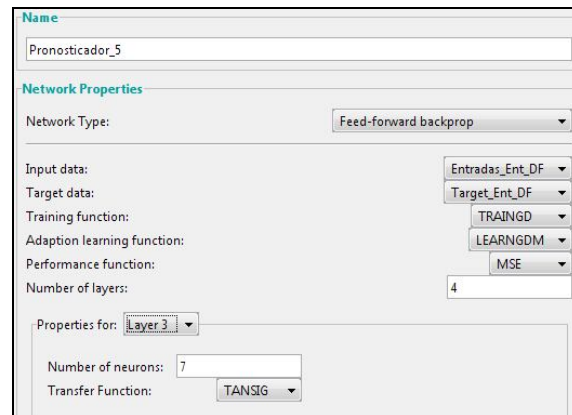


Figura 6.21. Configuración de la red PRONOSTICADOR\_5

- **Método**

RNA backpropagation creado bajo el entorno del NEWRAL NETWORK

- **Descripción**

La red neuronal creada muestra la siguiente configuración:

- Tipo de red: backpropagation
- Rango de las entradas: 0 y 1

- Función de Entrenamiento: TRAINGD función que actualiza los pesos y valores de los bias de acuerdo al método retropropagación de gradiente descendente.
- Función de Aprendizaje: LEARNGDM, función de aprendizaje de gradiente descendente con momentum de los pesos y bias.
- Función de Rendimiento: MSE, Función de rendimiento basado en el error cuadrado medio.
- Numero de capas: 5 ( 1 de entrada, 3 ocultas y 1 de salida) – Capa de entrada reconocida automaticamente por el MATLAB.
- Número de neuronas por capa: La primera capa cuenta con 9 neuronas en la capa de entrada, 7 neuronas en cada capa oculta y una neurona en la capa de salida. Véase la Figura 6.22.




Figura 6.22. Esquema de la red neuronal PRONOSTICADOR\_5

- Propiedades de las capas: ambas capas hacen uso de la función Tansig.
- Función de transferencia sigmoidea tangente e hiperbólica.
- Parámetros: Los parámetros de la red se muestran en la Figura 6.23.

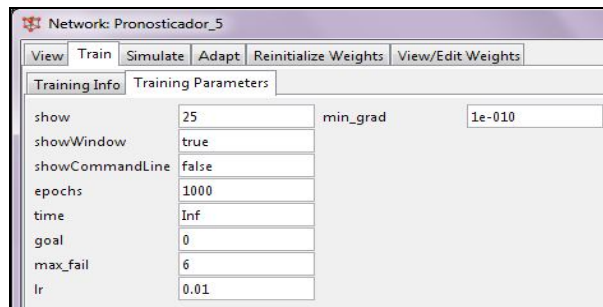


Figura 6.23. Configuración de los parámetros solicitados por la red PRONOSTICADOR\_5

- Configuración de pesos: Los pesos hallados de la red se muestra en la Figura 6.24.




Figura 6.24. Configuración de los pesos de la red PRONOSTICADOR\_5



- **Resultado**

El resultado que nos muestra el entrenamiento, *Figura 6.25.*, es el performance o rendimiento que usa la función del error cuadrático medio que es el siguiente:

**Error** → 0.0518

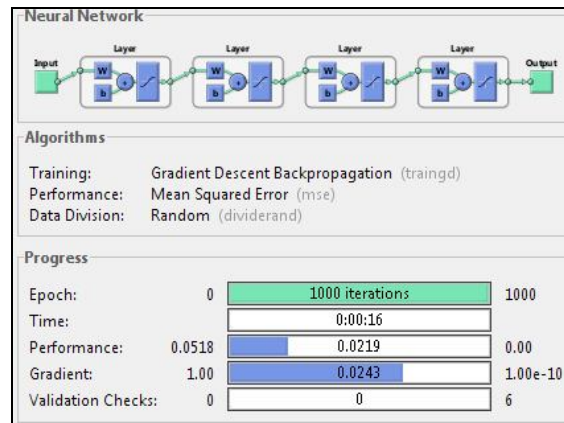


Figura 6.25. Imagen del entrenamiento realizado por la red PRONOSTICADOR\_5

#### 6.4.1.1.6. Configuración 6

**PRONOSTICADOR \_6.** Red Neuronal que muestra su configuración en la Figura 6.26.

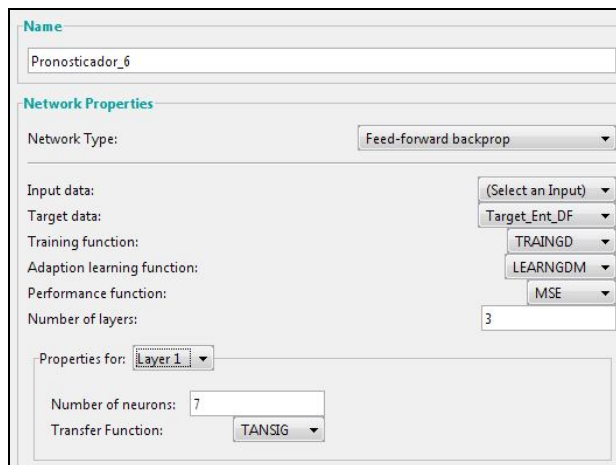


Figura 6.26. Configuración de la red PRONOSTICADOR\_6

- **Método**

RNA backpropagation creado bajo el entorno del NEWRAL NETWORK

- **Descripción**

La red neuronal creada muestra la siguiente configuración:

- Tipo de red: backpropagation

- Rango de las entradas: 0 y 1
- Función de Entrenamiento: TRAINGD función que actualiza los pesos y valores de los bias de acuerdo al método retropropagación de gradiente descendiente.
- Función de Aprendizaje: LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.
- Función de Rendimiento: MSE, Función de rendimiento basado en el error cuadrado medio.
- Numero de capas: 4 ( 1 de entrada, 2 ocultas y 1 de salida) – Capa de entrada reconocida automaticamente por el MATLAB.
- Número de neuronas por capa: La primera capa cuenta con 9 neuronas en la capa de entrada, 7 neuronas en cada capa oculta y una neurona en la capa de salida. Véase la Figura 6.27.




Figura 6.27. Esquema de la red neuronal PRONOSTICADOR\_6

- Propiedades de las capas: ambas capas hacen uso de la función Tansig.
- Función de transferencia sigmoidea tangente e hiperbólica.
- Parámetros: Los parámetros de la red se muestran en la Figura 6.28.

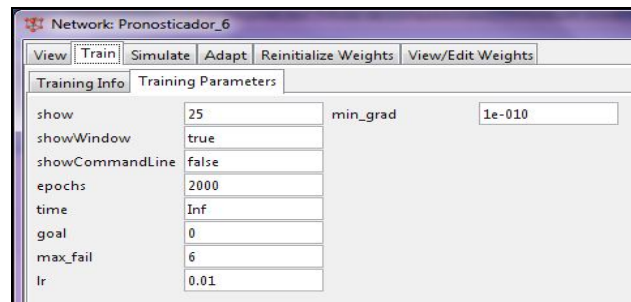


Figura 6.28. Configuración de los parámetros solicitados por la red PRONOSTICADOR\_6

- Configuración de pesos: Los pesos hallados de la red se muestra en la Figura 6.29.



Figura 6.29. Configuración de los pesos de la red PRONOSTICADOR\_6

- **Resultado**

El resultado que nos muestra el entrenamiento, Figura 6.30., es el performance o rendimiento que usa la función del error cuadrático medio que es el siguiente:

**Error** → 0.107

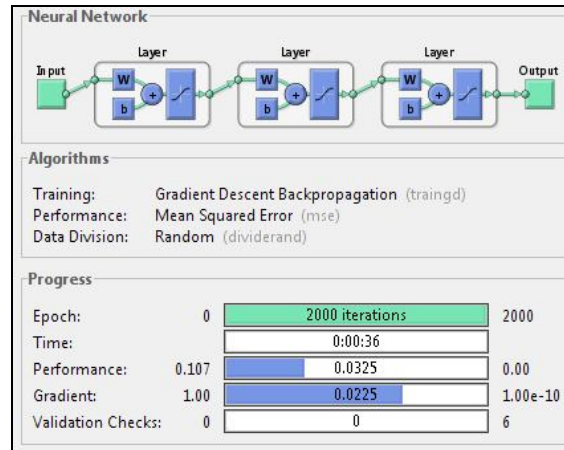


Figura 6.30. Imagen del entrenamiento realizado por la red PRONOSTICADOR\_6

#### 6.4.1.1.7. Configuración 7

**PRONOSTICADOR\_7.** Red Neuronal que muestra su configuración en la Figura 6.31.

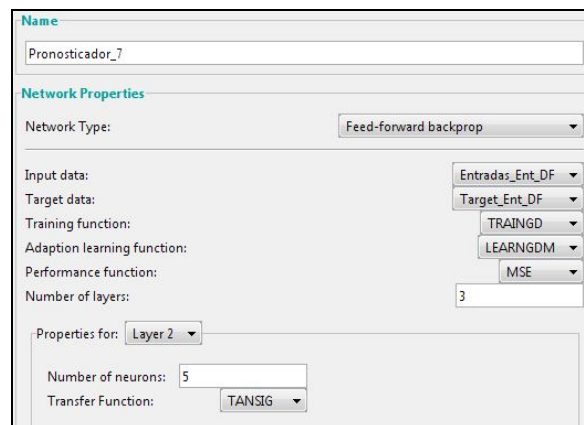


Figura 6.31. Configuración de la red PRONOSTICADOR\_7

- **Método**

RNA backpropagation creado bajo el entorno del NEWRAL NETWORK

- **Descripción**

La red neuronal creada muestra la siguiente configuración:

- Tipo de red: backpropagation
- Rango de las entradas: 0 y 1

- Función de Entrenamiento: TRAINGD función que actualiza los pesos y valores de los bias de acuerdo al método retropropagación de gradiente descendente.
- Función de Aprendizaje: LEARNGDM, función de aprendizaje de gradiente descendente con momentum de los pesos y bias.
- Función de Rendimiento: MSE, Función de rendimiento basado en el error cuadrado medio.
- Numero de capas: 4 ( 1 de entrada, 2 ocultas y 1 de salida) – Capa de entrada reconocida automaticamente por el MATLAB.
- Número de neuronas por capa: La primera capa cuenta con 9 neuronas en la capa de entrada, 5 neuronas en cada capa oculta y una neurona en la capa de salida. Véase la Figura 6.32.




Figura 6.32. Esquema de la red neuronal PRONOSTICADOR\_7

- Propiedades de las capas: ambas capas hacen uso de la función Tansig.
- Función de transferencia sigmoidea tangente e hiperbólica.
- Parámetros: Los parámetros de la red se muestran en la Figura 6.33.

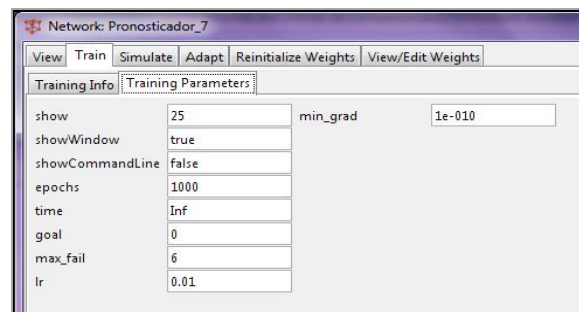


Figura 6.33. Configuración de los parámetros solicitados por la red PRONOSTICADOR\_7

- Configuración de pesos: Los pesos hallados de la red se muestra en la Figura 6.34.




Figura 6.34. Configuración de los pesos de la red PRONOSTICADOR\_7

- **Resultado**

El resultado que nos muestra el entrenamiento, Figura 6.35, es el performance o rendimiento que usa la función del error cuadrático medio que es el siguiente:

**Error** → 0.054

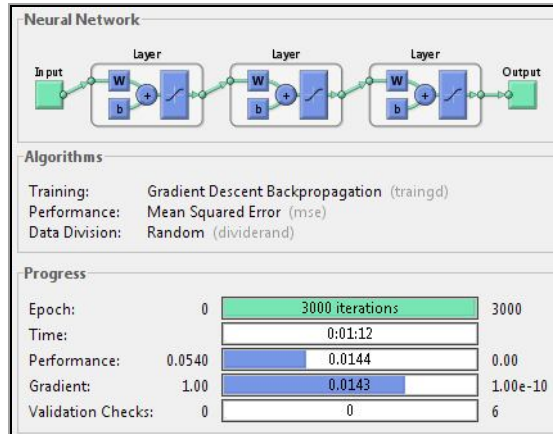


Figura 6.35. Imagen del entrenamiento realizado por la red PRONOSTICADOR\_7

#### 6.4.1.1.8. Configuración 8

**PRONOSTICADOR\_8.** Red Neuronal que muestra su configuración en la Figura 6.36.

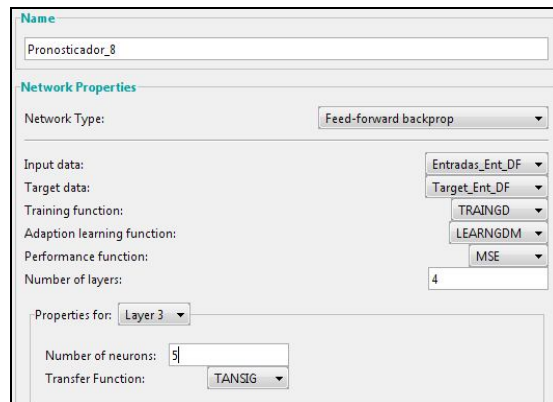


Figura 6.36. Configuración de la red PRONOSTICADOR\_8

- **Método**

RNA backpropagation creado bajo el entorno del NEWRAL NETWORK

- **Descripción**

La red neuronal creada muestra la siguiente configuración:

- Tipo de red: backpropagation
- Rango de las entradas: 0 y 1
- Función de Entrenamiento: TRAINGD función que actualiza los pesos y valores de los bias de acuerdo al método retropropagación de gradiente descendiente.

- Función de Aprendizaje: LEARN\_GDM, función de aprendizaje de gradiente descendente con momentum de los pesos y bias.
- Función de Rendimiento: MSE, Función de rendimiento basado en el error cuadrado medio.
- Numero de capas: 5 ( 1 de entrada, 3 ocultas y 1 de salida) – Capa de entrada reconocida automaticamente por el MATLAB.
- Número de neuronas por capa: La primera capa cuenta con 9 neuronas en la capa de entrada, 5 neuronas en cada capa oculta y una neurona en la capa de salida. Véase la Figura 6.37.




Figura 6.37. Esquema de la red neuronal PRONOSTICADOR\_8

- Propiedades de las capas: ambas capas hacen uso de la función Tansig.
- Función de transferencia sigmoidea tangente e hiperbólica.
- Parámetros: Los parámetros de la red se muestran en la Figura 6.38.

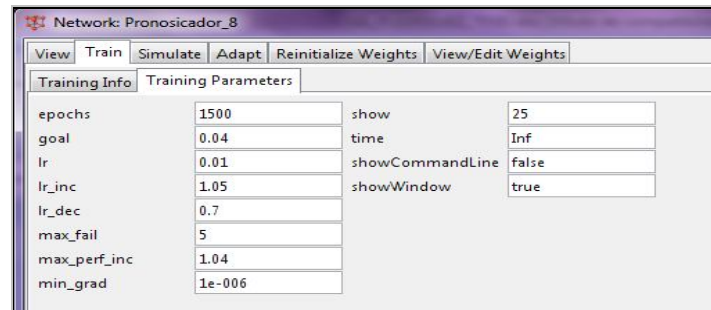


Figura 6.38. Configuración de los parámetros solicitados por la red PRONOSTICADOR\_8

- Configuración de pesos: Los pesos hallados de la red se muestra en la Figura 6.39.




Figura 6.39. Configuración de los pesos de la red PRONOSTICADOR\_8

• **Resultado**

El resultado que nos muestra el entrenamiento, Figura 6.40., es el performance o rendimiento que usa la función del error cuadrático medio que es el siguiente:

**Error** → 0.0300

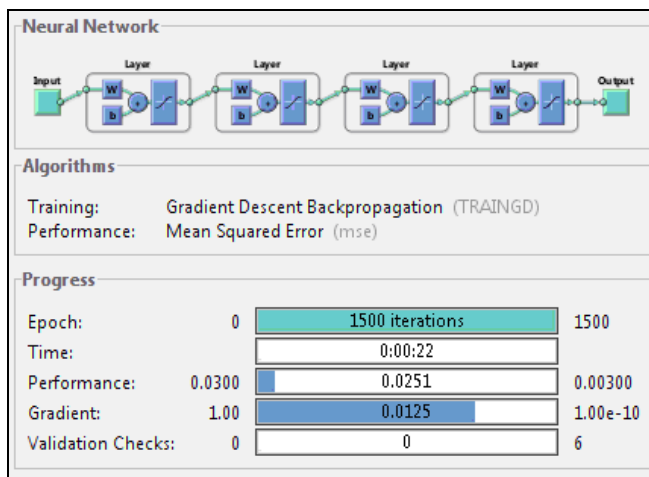


Figura 6.40 Imagen del entrenamiento realizado por la red PRONOSTICADOR\_8

### 6.4.1.2. Resumen del proceso de entrenamiento de la RN del producto DF

En la Tabla 6.6 se muestra el compendio de los resultados obtenidos en las 8 configuraciones de redes, en este resumen se muestran los datos más importantes empleados en el entrenamiento de cada red neuronal que referencian al nombre de la red, al número de neuronas por cada capa oculta (3 primeras columnas de la Tabla 6.6), luego se muestra el número de épocas realizadas por cada red en su respectivo entrenamiento y el rendimiento o performance equivalente a la función del error cuadrático medio (ECM). Del siguiente cuadro se deduce que las 3 configuraciones más adecuadas son: Pronosticador\_3, pronosticador\_5 y el Pronosticador\_8 puesto que estas redes poseen los menores valores correspondientes al ECM.

Resultados Obtenidos					
Red Neuronal	Capas ocultas			Épocas	ECM
	Capa 1	Capa 2	Capa 3		
Pronosticador_1	6	6	0	12	0.0872
Pronosticador_2	7	7	7	25	0.1640
<b>Pronosticador_3</b>	<b>6</b>	<b>6</b>	<b>6</b>	<b>6</b>	<b>0.0277</b>
Pronosticador_4	7	7	7	9	0.1010
<b>Pronosticador_5</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>1000</b>	<b>0.0518</b>
Pronosticador_6	7	7	0	2000	0.1070
Pronosticador_7	5	5	0	3000	0.0540
<b>Pronosticador_8</b>	<b>5</b>	<b>5</b>	<b>5</b>	<b>1500</b>	<b>0.0300</b>

Tabla 6.6. Resumen del proceso de entrenamiento de la RN del producto DF

### 6.4.1.3. Configuración escogida para el Producto DF

Las configuraciones escogidas son las redes seleccionadas de acuerdo a la obtención del mejor rendimiento en el resumen del proceso de entrenamiento que se muestra en la Tabla 6.6 de la sección anterior, estas redes serán empleadas para la fase de validación.

La primera red seleccionada es la red “*Pronosticador\_3*”, pues posee el menor error cuadrático medio entre todas las redes entrenadas cuyo valor es 0.0277, la segunda es la red “*Pronosticador\_5*” cuyo valor de ECM es 0.518 y la tercera es la red “*Pronosticador\_8*” que presenta un error de 0.030. Estas 3 redes serán empleadas para la fase de validación donde apartir del ECM que cada una de ellas proyecte seleccionaremos la red más adecuada para el pronóstico de la cantidad demanda del producto DF.

### 6.4.2. Proceso de entrenamiento de la RNA del producto RG

Para el producto RG se han utilizado las configuraciones presentadas para las redes del producto DF. A continuación, sólo se muestran los resultados obtenidos en cada entrenamiento, es decir los ECM (errores cuadráticos medios).

Resultados Obtenidos – Producto RG					
Red Neuronal	Capas ocultas			Épocas	ECM
	Capa 1	Capa 2	Capa 3		
Pronosticador_1	6	6	0	12	0.0642
<b>Pronosticador_2</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>39</b>	<b>0.0637</b>
Pronosticador_3	6	6	6	6	0.1150
<b>Pronosticador_4</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>12</b>	<b>0.0534</b>
Pronosticador_5	7	7	7	1000	0.2110
Pronosticador_6	7	7	0	1245	0.0892
<b>Pronosticador_7</b>	<b>5</b>	<b>5</b>	<b>0</b>	<b>3465</b>	<b>0.0285</b>
Pronosticador_8	5	5	5	1500	0.111

Tabla 6.7. Resumen del proceso de entrenamiento de la RN del producto RG

Las configuraciones escogidas son: “*Pronosticador\_7*”, pues posee el menor error cuadrático medio entre todas las redes entrenadas cuyo valor es 0.02885, la segunda es la red “*Pronosticador\_4*” cuyo ECM es 0.534 y la tercera es la red “*Pronosticador\_2*” que presenta un error de 0.0637. Estas 3 redes serán empleadas para la fase de validación donde apartir del ECM que cada una de ellas proyecte seleccionaremos la red más adecuada para el pronóstico de la cantidad demanda del producto RG.



### 6.4.3 Proceso de entrenamiento de la RNA del producto CH

En la siguiente tabla se muestran los resultados obtenidos de las configuraciones de 8 redes neuronales para pronosticar la cantidad demanda del producto CH, cada configuración ha sido realizada siguiendo los pasos del proceso de entrenamiento de las RNA producto DF. La Tabla 6.8 detalla cada una de las configuraciones y remarca las 3 redes neuronales más apropiadas para la fase de validación.

Resultados Obtenidos – Producto CH					
Red Neuronal	Capas ocultas			Épocas	ECM
	Capa 1	Capa 2	Capa 3		
<b>Pronosticador_1</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>15</b>	<b>0.00044</b>
<b>Pronosticador_2</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>100</b>	<b>0.00540</b>
<b>Pronosticador_3</b>	<b>7</b>	<b>7</b>	<b>0</b>	<b>1500</b>	<b>0.01258</b>
Pronosticador_4	6	6	0	71	0.01736
Pronosticador_5	7	7	7	1000	0.03621
Pronosticador_6	7	7	0	500	0.05840
Pronosticador_7	5	5	0	36	0.36520
Pronosticador_8	5	5	5	1000	0.20650

Tabla 6.8. Resumen del proceso de entrenamiento de la RN del producto CH

La primera red seleccionada es la red “**Pronosticador\_1**”, pues posee el menor error cuadrático medio entre todas las redes entrenadas cuyo valor es 0.00044, la segunda es la red “**Pronosticador\_2**” cuyo valor de ECM es 0.0054 y la tercera es la red “**Pronosticador\_3**” que presenta un error de 0.01258. Estas 3 redes serán empleadas para la fase de validación donde seleccionaremos la red más adecuada para el pronóstico de la cantidad demanda del producto CH.

## 6.5. Fase de validación

La fase de validación representa el grado de generalización de la red neuronal, en otras palabras, es la capacidad de la red de dar una respuesta correcta ante patrones que no han sido usadas en su entrenamiento.

### 6.5.1. Validación de las redes del producto DF

El proceso de validación de las redes neuronales seleccionadas en la sección 6.4.1. PRONOSTICADOR\_3, PRONOSTICADOR\_5 y PRONOSTICADOR\_8 se realizó utilizando la interfaz del *neural network (NNTool)* de la caja de herramientas de MATLAB, cuyo procedimiento, resultado y pruebas se mostrará a continuación.

### 6.5.1.1 Procedimiento en MatLab

Se presentaron a las redes los datos correspondientes a las instancias de validación que se había reservado previamente en la Tabla 6.5. Cada red procesó esta nueva información teniendo en cuenta las relaciones aprendidas en el entrenamiento que guarda (recuerda) en forma de vector de pesos sinápticos. La salida de la red será la cantidad prevista de la demanda del producto DF. Comparando esta predicción con el valor real de la carga podremos contrastar la capacidad predictiva del modelo.

En la Figura 6.41 se muestra la forma en que se valida la red seleccionada en la etapa anterior, en la pestaña SIMULATE del MATLAB se cargan las entradas para la validación y las salidas para la misma. En la Figura 6.41 se muestra el vector de error de validación, es decir, los errores resultantes en esta etapa.




Figura 6.41. Simulación con los datos de validación para la red PRONOSTICADOR\_8




Figura 6.42. Errores de la validación PRONOSTICADOR\_8

### 6.5.1.2 Tasa de error

La tasa de error será medida utilizando la fórmula del error cuadrático medio para comprobar que el tipo de red seleccionado es el más adecuado.

$$E_c = \frac{1}{N} \sum_{i=1}^N \|y^i - s^i(w)\|^2$$

Donde:

Ec = Error cuadrático.

N = Número de muestras en la validación.

Y i = Salida objetivo de la red para la muestra i.

S i (w) = salida estimada de la red para la muestra i.

En nuestro caso el valor de N es igual a 12 de acuerdo a los datos de la Tabla 6.5. (instancias para la fase de validación – 9 meses del año 2009 y primer trimestre del año 2010). A continuación en la Tabla 6.9. se observan los resultados obtenidos:

Resultados Obtenidos – Producto DF				
Red Neuronal	Capas Ocultas			ECM
	Capa 1	Capa 2	Capa 3	
Pronosticador_3	6	6	6	<b>0.10500</b>
Pronosticador_5	7	7	7	<b>0.08020</b>
<b>Pronosticador_8</b>	<b>5</b>	<b>5</b>	<b>5</b>	<b>0.01080</b>

Tabla 6.9. Resumen del proceso de validación – Producto DF

### 6.5.2 Validación de la redes del Producto RG

El proceso de validación es similar al del producto DF. En este caso las redes neuronales seleccionadas en la sección anterior son: **PRONOSTICADOR\_2**, **PRONOSTICADOR\_4** y **PRONOSTICADOR\_7**. Para este producto se ha realizado la validación con 6 registros, de acuerdo a los datos del anexo E. (instancias correspondientes a los 3 meses del año 2009 y primer trimestre del año 2010). A continuación en la Tabla 6.10. se observan los resultados obtenidos:

Resultados Obtenidos – Producto RG				
Red Neuronal	Capas Ocultas			ECM
	Capa 1	Capa 2	Capa 3	
Pronosticador_2	7	7	7	<b>0.7822</b>
Pronosticador_4	7	7	7	<b>0.0562</b>
<b>Pronosticador_7</b>	<b>5</b>	<b>5</b>	<b>0</b>	<b>0.0236</b>

Tabla 6.10. Resumen del proceso de validación – Producto RG

### 6.5.3 Validación Producto CH

El proceso de validación es similar al del producto DF. En este caso las redes neuronales seleccionadas en la sección anterior son: **PRONOSTICADOR\_1**, **PRONOSTICADOR\_2** y **PRONOSTICADOR\_3**. Para este producto se ha realizado la validación con 6 registros, de acuerdo a los datos del anexo E. (instancias para la fase de validación – primer semestre del año 2008). A continuación en la Tabla 6.11. se observan los resultados obtenidos:

Resultados Obtenidos – Producto CH				
Red Neuronal	Capas Ocultas			ECM
	Capa 1	Capa 2	Capa 3	
<b>Pronosticador_1</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>0.00221</b>
Pronosticador_2	7	7	7	0.02645
Pronosticador_3	7	7	0	0.01800

Tabla 6.11. Resumen del proceso de validación – Producto CH

## 6.6. Sistema de pronóstico

En esta última etapa el software, que será utilizado por el usuario encargado de las previsiones, está implementado con el IDE de JAVA, NetBeans 6.5, J.D.K. 5.0. ya que esta version provee las herramientas necesarias para la creación de una interfaz gráfica amigable para el usuario.

### 6.6.1. Conexión JAVA - MATLAB:

La herramienta usada para la creación de la red es el MATLAB y el lenguaje utilizado para la creación de la interfaz gráfica es JAVA, por lo cual se necesita una librería especial que realizará la conexión entre ambos lenguajes: el *JmatLink*

- **JmatLink.**

Es una librería que contiene clases predefinidas para ejecutar comandos en MATLAB desde una aplicación de Java. Cuenta con 3 clases especiales:

- *jmatlink*.
- *corejmatlink*
- *jmatlinkexception*.

Estas 3 clases funcionan de manera agrupada para realizar la conexión entre ambos lenguajes dentro de un paquete llamado “jmatlink” que se coloca dentro de nuestro proyecto. El dll que trae incorporado se coloca en: C:\windows\system32 para que realice las funciones internamente.

#### **Ejemplo:**

```
import jmatlink.*; // Se importa la clase jmatlink con todos sus componentes
class Prueba
{
    private JMatLink conMatlab; // Se declara una variable de conexión
    Prueba()
    {
        conMatlab = new JMatLink(); // Se crea una instancia de la clase JmatLink
    }
    public void conectarMatlab()
    {
        conMatlab.engOpen(); // Se abre la conexión
        conMatlab.engEvalString("surf(peaks)"); // Se ingresa un comando a ejecutar
        conMatlab.engClose(); // Se cierra la conexión
    }
    public static void main(String[] args)
    {
        Prueba p = new Prueba();
        p.conectarMatlab();
    }
}
```

A continuación se describen las principales funciones utilizadas:

- *engOpen()*: Apertura la conexión
- *engEvalString(string)*: Envía una cadena que se ejecutará en matlab.
- *engGetArray(b)*: Función que recupera el valor generado en matlab.
- *engClose()*:Función que cierra la conexión.

### 6.6.2. Interfaz de usuario

La interfaz de usuario es muy importante para la correcta comprensión del sistema por parte de la persona encargada de realizar las previsiones, sin una adecuada presentación éste no será capaz de obtener los resultados deseados. A continuación se muestran los pasos para su implementación:

- Una vez concluida la fase de entrenamiento y validación y después de haber escogido la red que brinda la respuesta más adecuada ésta se guarda en formato “mat” (archivo de matlab ejecutable en la ventana de comandos) y luego se almacena en una carpeta o unidad de trabajo (C,D, etc).
- Se coloca el archivo JmatLink.dll en la carpeta : C:\WINDOWS\system32.
- Se ejecuta el programa construido en Java.

- **Acceso al sistema**

El acceso al sistema (Véase la Figura 6.43.) esta diseñado para poder diferenciar los dos tipos de usuarios que existen en el sistema, usuario operador y usuario administrador. A continuación se detallan estos dos tipos.

- **Usuario operador.** Es la persona encargada de realizar únicamente de los pronósticos de los productos registrados

**Funciones:**

- *Elegir el producto.*
- *Ingresar los parámetros para el pronóstico.*
- *Obtener la cantidad pronosticada.*

- **Usuario administrador.** Es la persona encargada del mantenimiento de las redes para los respectivos pronósticos.

**Funciones:**

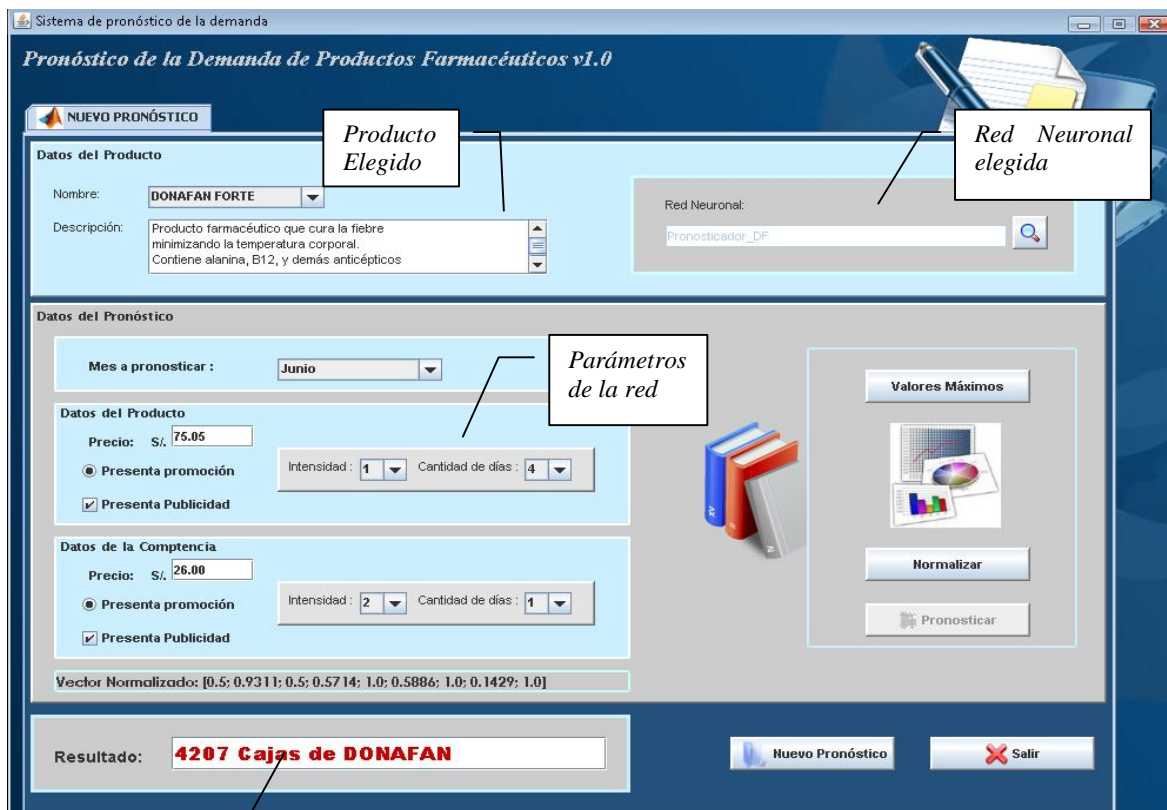
- *Crear nuevas redes de acuerdo al contexto de los nuevos datos de los productos.*
- *Entrenar dichas redes para la obtención de las redes más adecuadas por cada producto seleccionado.*
- *Validar el funcionamiento de la red de acuerdo a los datos del producto.*
- *Realizar pronósticos de los productos registrados.*
- *Configurar los valores máximos de los parámetros indicados para el entrenamiento de la RNA (entradas de la red).*



Figura 6.43. Acceso al sistema de pronóstico.

6.6.2.1. Usuario: Operador.

El usuario operador estará encargado de obtener el resultado del pronóstico de acuerdo a los parámetros ingresados para un determinado mes. La Figura 6.44. muestra la interfaz diseñada.



Salida  
Pronosticada

Figura 6.44. Interfaz de pronóstico – usuario operador

6.6.2.2. Usuario: *Administrador*.

El usuario administrador no sólo estará encargado de realizar los pronóstico de la demanda de productos farmacéuticos sino también estará encargado de la administración de los mismos esto implica la configuración y creación de nuevas redes y la validación de redes existentes.

La realización de una predicción que también está explicada en la sección anterior es la misma que se ve en la Figura 6.45. que muestra la interfaz que realiza el pronóstico de un cierto producto farmacéutico, la Figura 6.46. muestra el panel de configuración de los valores mínimos y máximos, la Figura 6.47. muestra la interfaz para la creación de una nueva red y la Figura 6.48. muestra la validación de una red creada.

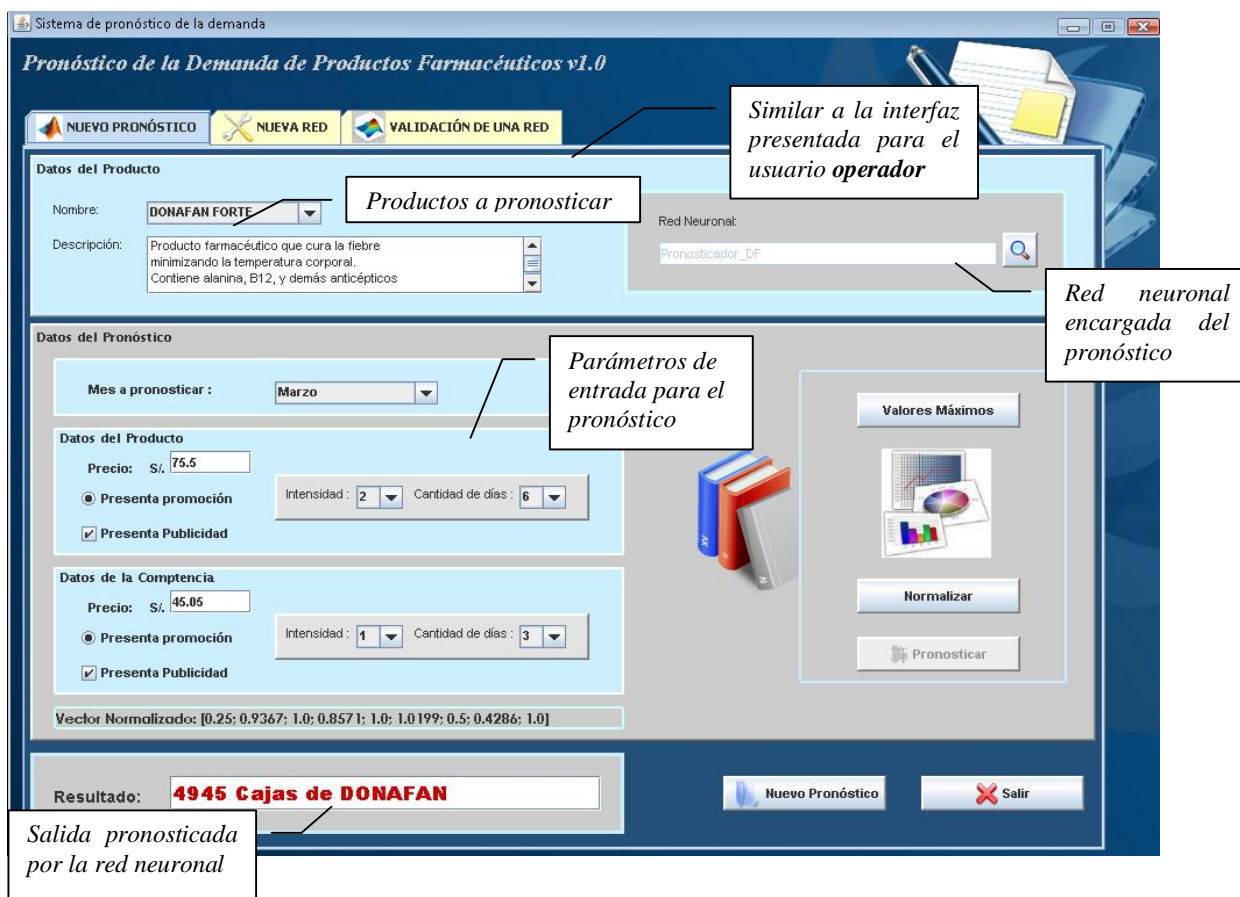


Figura 6.45. Interfaz de pronóstico – Usuario Administrador

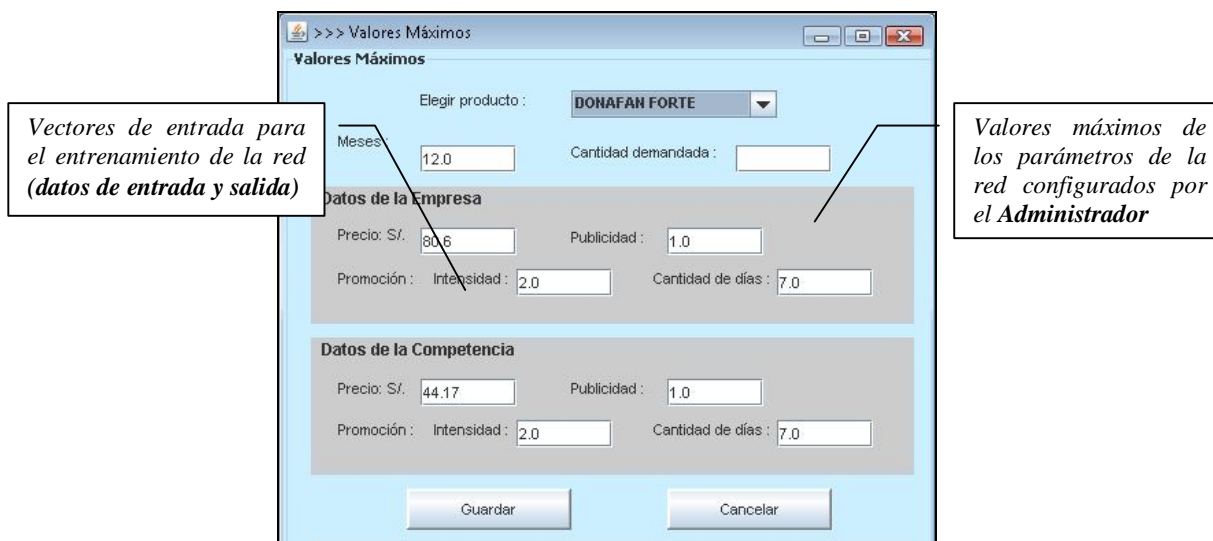


Figura 6.46. Configuración de los valores máximos del producto elegido

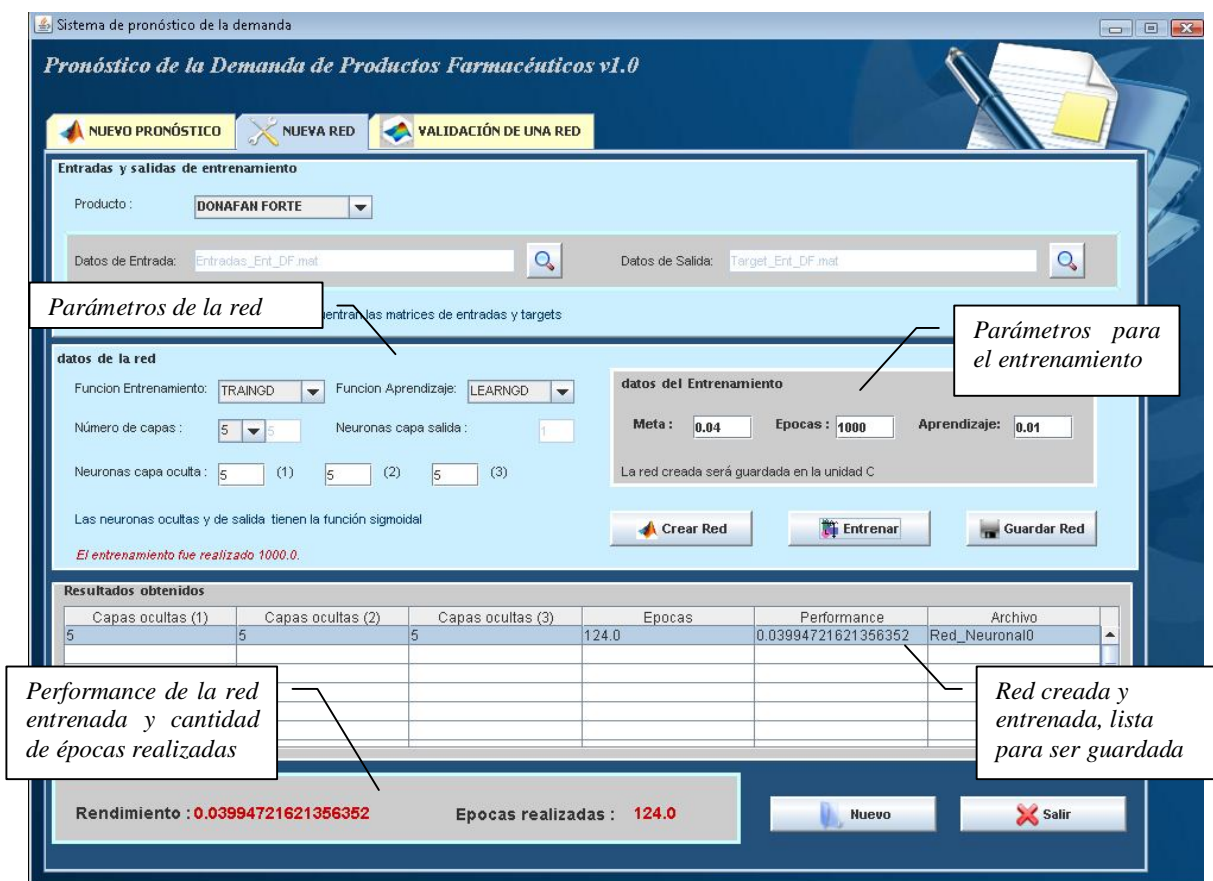


Fig. 6.47. Creación y entrenamiento de una RNA



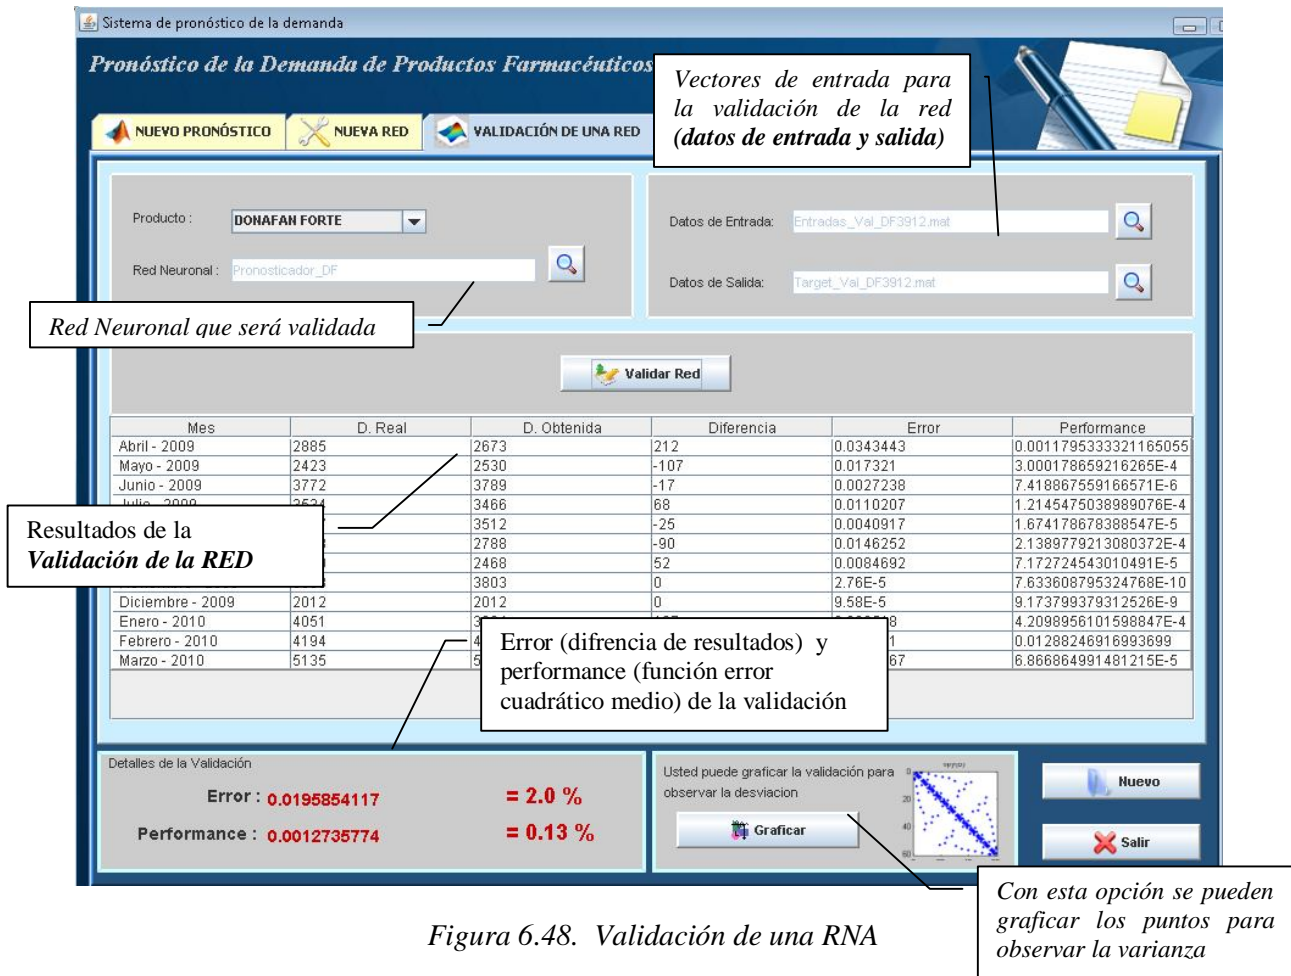


Figura 6.48. Validación de una RNA

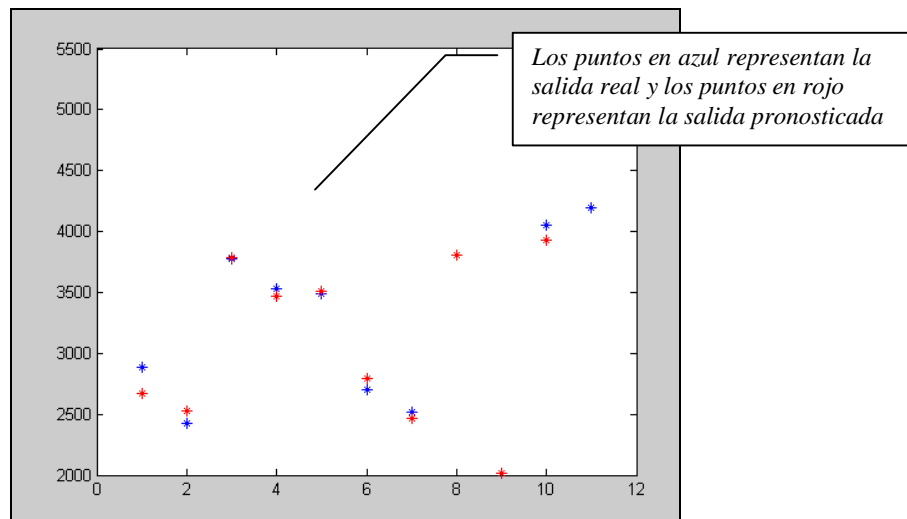


Figura 6.49. Gráfica de la validación de la red neuronal

### 6.6.3. Prueba del sistema

A continuación en la Figura 6.50. se muestra una prueba del correcto funcionamiento de la interfaz de pronóstico tomando como parámetros un dato de la validación.

- **Parámetros de entrada.**
  - Nombre del producto: **Donafan Forte**
  - Nombre de la red neuronal: **Pronosticador\_DF (Donafan)**
  - Mes a pronosticar: **Marzo**
  - Precio del producto : **S/. 79.00**
  - Presenta publicidad y promoción de intensidad **1** realizada por **1** día.
  - Precio del producto similar de la competencia: **S/. 29.00**
  - La competencia presenta publicidad
  - Presenta promoción de intensidad **2** realizada por **5** días.
- **El vector normalizado** se muestra en la parte inferior
- **El resultado es 1837 cajas de DONAFAN** aproximadamente

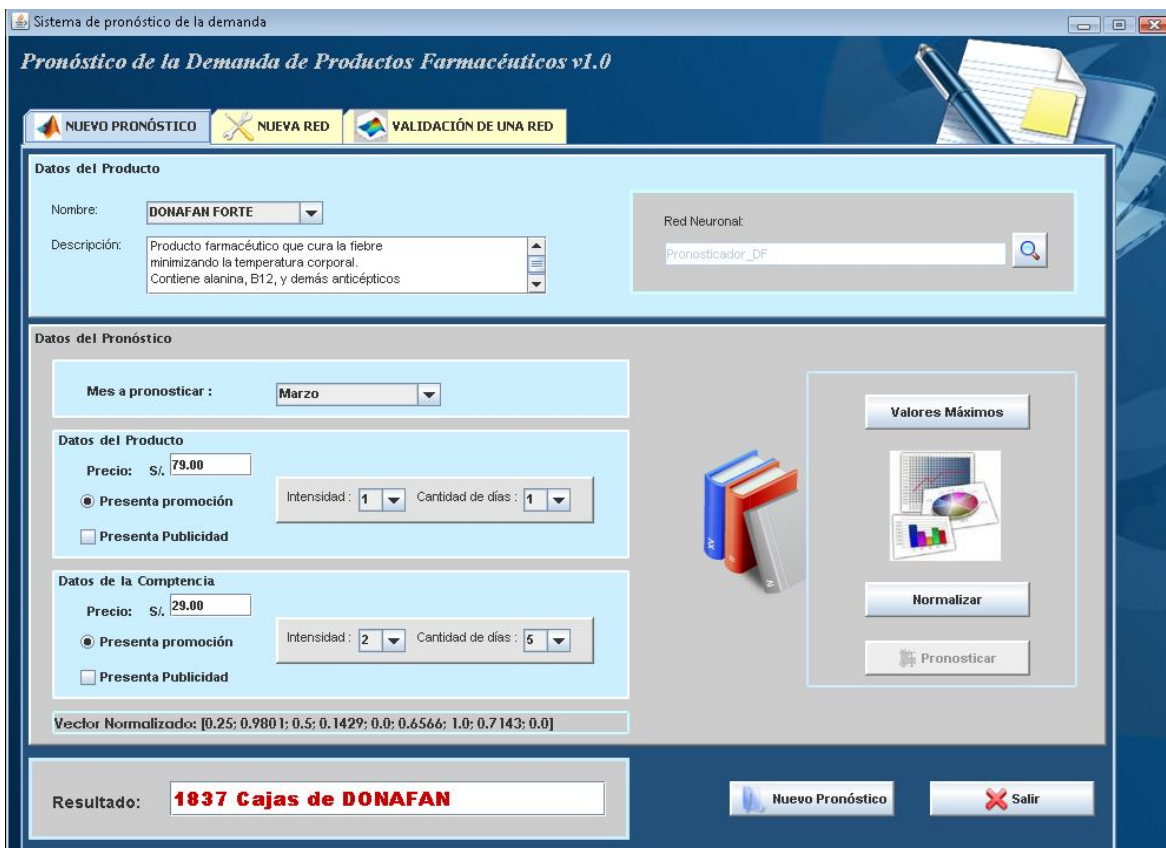


Figura 6.50. Prueba del sistema

**6.6.4. Rendimiento de las redes neuronales frente al experto.**

Todo el trabajo realizado no será de mucho beneficio si la persona encargada de las previsiones realiza pronósticos de ventas más acertados que las redes neuronales propuestas. Nuestro objetivo más trascendental es poder pronosticar la cantidad demandada con un margen de error mínimo o menor a la del experto. Para poder demostrar esta presunción presentamos evidencias en la Tabla 6.8. que demuestran que nuestra red neuronal predice las cantidades demandadas con menor margen de error que el experto.

Primero se explicará como se ha determinado los valores de cada columna que interviene en la comparación de los pronósticos de los productos.

- **Cantidad prevista por el experto:** Es la cantidad que el experto en la empresa calcula se venderá en el mes dado de acuerdo a la siguiente fórmula estadística:

$$CP_i = (CD_{i-1} + CD_{i-2} + CD_{i-3}) / 3$$

Donde:

- $CP_i$  → Cantidad Pronosticada del mes i
- $CD_{i-1}$  → Cantidad Demanda Real del mes i-1
- $CD_{i-2}$  → Cantidad Demanda Real del mes i-2
- $CD_{i-3}$  → Cantidad Demanda Real del mes i-3

**Ejemplo para el producto DF:**

Mes = Agosto 2007 donde i= 8

$$CP = (CD(\text{Julio}) + CD(\text{Junio}) + CD(\text{Mayo}))/3$$

$$CP = (2025 + 2853 + 4951)/3$$

$$CP = 3276 \text{ cajas de DF}$$

Se debe tener en cuenta que si la cantidad pronosticada se vende antes del término del mes, la empresa vuelve a calcular la cantidad pronosticada para el tiempo restante del mismo mes, por ejemplo en el mes de Agosto del 2007 la cantidad demandada real fue de 4225 cajas del producto DF, significa que los 3276 se terminó de vender el día 22 de dicho mes.

El experto observó que para el día 20 había en stock 50 cajas de DF, por lo que la decisión tomada es de comprar más cajas por lo que la cantidad a comprar para cubrir el mes sería.

$$CP_{ri} = ((CP_i / DM) \times DC) - \text{stock}$$

Donde:

- $CP_{ri}$  → Cantidad Pronosticada para el resto de días del mes i
- $DC$  → Cantidad de días por cubrir
- $DM$  → Días del mes
- $Stock$  → Stock del producto

Prosiguiendo con el ejemplo del mes de Agosto del 2007 se tiene:

$$CP_{ri} = ((CP(\text{Agosto}) / 31) * 11) - 50$$

$$CP_{ri} = ((3276 / 31) * 11) - 50$$

$$CP_{ri} = 1113 \text{ cajas de DF}$$

- **Cantidad pronosticada por la RN:** Esta es la cantidad pronosticada por la red neuronal del sistema propuesto, en el cual se le ingresan los valores de entrada y éste determina la cantidad pronosticada para dicho mes.
- **Demanda real:** Esta es la cantidad real de ventas que ha sido proporcionada a la empresa.
- **Error del experto:** Esta cantidad representa la diferencia entre la cantidad pronosticada por la empresa y la demanda real.
- **Error de la RN:** Esta cantidad representa la diferencia entre la cantidad pronosticada por la red Neuronal y la demanda real.

En la Tabla 6.12. se muestra el cuadro comparativo entre las cantidades pronosticadas por el experto encargado de realizar las previsiones en la empresa FARMOTC y las cantidades pronosticadas por la red neuronal PRONOSTICADOR\_8 entrenada y validada para el producto DF, así mismo se muestran los errores por cada mes de la red neuronal y del experto tomando como referencia los últimos 9 meses del año 2009 y el primero trimestre del 2010 que corresponden a los datos de validación.

Resultados Obtenidos – Producto DF						
i	Mes	Cantidad prevista por el experto	Cantidad pronosticada por la RN	Demanda real	Error del experto	Error de la RN
1	Abril - 2009	4782	2673	2885	1897	212
2	Mayo - 2009	3904	2530	2423	1481	107
3	Junio - 2009	2657	3789	3772	1115	17
4	Julio - 2009	3027	3466	3534	507	68
5	Agosto - 2009	3243	3512	3487	244	25
6	Setiembre - 2009	3598	2788	2698	900	90
7	Octubre - 2009	3240	2468	2520	720	52
8	Noviembre - 2009	2902	3803	3803	901	0
9	Diciembre - 2009	3007	2012	2012	995	0
10	Enero - 2010	2778	3924	4051	1273	127
11	Febrero - 2010	3289	4893	4194	905	699
12	Marzo - 2010	3419	5084	5135	1716	51
<b>TOTAL</b>		<b>39846</b>	<b>40942</b>	<b>40514</b>	<b>12654</b>	<b>1448</b>
<b>Error Promedio = (100 * [SUM(Ei) / SUM(CantidadReal i)] )%</b>					<b>31,23 %</b>	<b>3,57%</b>

Tabla 6.12. Cuadro comparativo del producto DF (cantidades del experto vs. cantidades de la RN)

De los resultados mostrados se deduce que la red neuronal propuesta obtiene mejores predicciones que el experto encargado de las previsiones en la empresa puesto que el ECM obtenido por la RN es de 3,57% valor que es mucho menor comparado con el 31,23% del ECM del experto.

$$Error(RN)_{DF} < Error(experto)_{DF} \rightarrow 3,57\% < 31,23\%$$

En la Tabla 6.13. se muestra el cuadro comparativo entre las cantidades pronosticadas por el experto encargado de realizar las previsiones en la empresa FARMOTC y las cantidades pronosticadas por la red neuronal PRONOSTICADOR\_7 entrenada y validada para el producto RG, así mismo se muestran los errores por cada mes de la red neuronal y del experto tomando como referencia los últimos 3 meses del año 2009 y el primero trimestre del 2010 que corresponden a los datos de validación.

Resultados Obtenidos – Producto RG						
i	Mes	Cantidad prevista por el experto	Cantidad pronosticada por la RN	Demanda real	Error del experto	Error de la RN
1	Octubre - 2009	4746	9475	9244	4,498	231
2	Noviembre - 2009	6395	10206	9758	3,363	448
3	Diciembre - 2009	8011	5265	5817	2,194	552
4	Enero - 2010	6606	7464	7661	1,055	197
5	Febrero - 2010	5745	7282	6775	1,030	507
6	Marzo - 2010	4084	5365	5647	1,563	282
<b>TOTAL</b>		<b>35586</b>	<b>45057</b>	<b>44902</b>	<b>13703</b>	<b>2217</b>
<b>Error Promedio = (100 * [SUM(Ei) / SUM(CantidadReali)]) %</b>					<b>30,52 %</b>	<b>4,93%</b>

Tabla 6.13. Cuadro comparativo del producto RG (cantidades del experto vs. cantidades de la RN)

De los resultados mostrados se deduce que la red neuronal propuesta obtiene mejores predicciones que el experto encargado de las previsiones en la empresa puesto que el ECM obtenido por la RN es de 4,93% valor que es mucho menor comparado con el 30,52% del ECM del experto.

$$Error(RN)_{RG} < Error(experto)_{RG} \rightarrow 4,93\% < 30,52\%$$

En la Tabla 6.14. se muestra el cuadro comparativo entre las cantidades pronosticadas por el experto encargado de realizar las previsiones en la empresa FARMOTC y las cantidades pronosticadas por la red neuronal PRONOSTICADOR\_1 entrenada y validada para el producto CH, así mismo se muestran los errores por cada mes de la red neuronal y del experto tomando como referencia el último semestre del año 2008 que corresponden a los datos de validación.

<b>Resultados Obtenidos – Producto CH</b>						
<b>i</b>	<b>Mes</b>	<b>Cantidad prevista por el experto</b>	<b>Cantidad pronosticada por la RN</b>	<b>Demanda real</b>	<b>Error del experto</b>	<b>Error de la RN</b>
1	Julio - 2008	12962	15958	15034	2072	924
2	Agosto - 2008	13653	15608	14294	641	1314
3	Setiembre - 2008	14039	13921	15707	1668	1786
4	Octubre - 2008	15012	13970	13075	1937	895
5	Noviembre - 2008	14359	15438	16196	1837	758
6	Diciembre - 2008	14993	15426	15477	484	51
<b>TOTAL</b>		<b>85016</b>	<b>90321</b>	<b>89783</b>	<b>8640</b>	<b>5728</b>
<b>Error Promedio = (100 * [SUM(Ei) / SUM(CantidadReali)]) %</b>					<b>9,623 %</b>	<b>6,380 %</b>

Tabla 6.14. Cuadro comparativo del producto CH (cantidades del experto vs. cantidades de la RN)

De los resultados mostrados en la Tabla 6.14 se deduce que la red neuronal propuesta obtiene mejores predicciones que el experto encargado de las previsiones en la empresa puesto que el ECM obtenido por la RN es de 6,38% valor que es mucho menor comparado con el 9,623% del ECM del experto.

$$Error(RN)_{CH} < Error(experto)_{CH} \rightarrow 6,38\% < 9,623\%$$

# *Capítulo 7*

## *Conclusiones y trabajos futuros*

### **7.1. Conclusiones**

- En este trabajo se ha presentado la importancia que tiene para las organizaciones actuales la correcta previsión de la demanda, pues ella se convierte en una herramienta de gran valor para llevar a cabo una adecuada planificación empresarial.
- La mayoría de empresas utilizan los modelos estadísticos para realizar sus pronósticos, gracias a estos se ha podido evolucionar a modelos más complejos y exactos como las redes neuronales.
- Se ha presentado los diversos modelos que existen para el pronóstico y se ha llegado a la conclusión de que las redes neuronales son las más adecuadas para la solución, puesto que se ha inferido su eficacia de acuerdo a muchos trabajos realizados que demuestran que las Redes Neuronales, gracias a su capacidad de «aprender» a partir de los ejemplos que se le proporcionan, sin hacer suposiciones a priori sobre los modelos y relaciones que subyacen en la serie, pueden ser aplicadas directamente, lo que facilita considerablemente el proceso de cálculo para pronosticar.
- Se ha mostrado la comparación de los tipos de redes neuronales y, de acuerdo a sus características, se ha seleccionado el perceptrón multicapa, para el cual hemos realizado la topología de red correspondiente. El perceptrón multicapa va acompañado del algoritmo de aprendizaje backpropagation.
- La red neuronal seleccionada nos muestra el patrón de comportamiento de la demanda de los productos farmacéuticos. Las variables que han sido identificadas han sido cuantificadas de acuerdo a datos históricos brindados por la empresa FARMOTC y gracias a la ayuda del experto que labora en dicha empresa.
- Se elaboró la arquitectura de la red neuronal más apropiada para el pronóstico de la demanda del producto DF distribuido por la empresa FARMOTC.
- Se desarrolló un software de predicción basado en la técnica de redes neuronales bajo la plataforma de lenguaje de programación JAVA, haciendo uso de una herramienta brindada por el MATLAB (Neural Network), que ofrece la posibilidad de diseñar una red ajustada al desarrollo de nuestro problema.
- Los resultados obtenidos son buenos ya que con la poca cantidad de datos históricos se llegó a un margen de error del producto DF del 3,57 % que comparado con el error del 31,23% de la persona encargada de las compras (error experto – mediante un sistema) es bastante menor. Así mismo los márgenes de error del 4,93 % y 6,38 % correspondientes a los productos RG y CH respectivamente son menores a los errores del experto.

## **7.2. Trabajos futuros**

- Se desearía realizar una lectura de datos desde una base de datos para almacenarlos debidamente. De igual forma se esperaría extender el sistema para la creación de nuevas redes que pronostiquen la cantidad demandada de los productos restantes mencionados en el aporte teórico.
- Así mismo se desea ampliar el número de parámetros y su variabilidad para obtener una mayor precisión en los pronósticos realizados de acuerdo a los cambios que ocurran en el entorno de la distribuidora mencionada.



# *Referencias bibliográficas*

- [Armstrong+06] J. Scott Armstrong, Kesten C. Green, Demand Forecasting: Evidence-based Methods, Department of Econometrics and Business Statistics, Monash University, 13/01/2006
- [Barrientos+07] Andrés Felipe Barrientos, Javier Olaya, Victor Manuel Gonzáles, A Spline Model for Electricity demand Forecasting, *Revistas Colombiana de Estadística*, V. 30, n. 2, 2007, pp 187-202.
- [Broomhead+88] D.S. Broomhead, D. Lowe, Multivariate functional interpolation and adaptive Networks. *Complex Systems* 2, 1988, pp.321-355.
- [Cox+02] 671 Louis A. Cox Jr., Douglas A. Popke, A hybrid system-identification method for forecasting telecommunications product demands, *International Journal of Forecasting*, v. 18, n. 4, 2002, pp. 647-671
- [Charytoniuk+00] Charytoniuk, W. Box, E.D. Lee, W.-J. Chen, M.-S. Kotas, P. Van Olinda, P. Neural-network-based demand forecasting in a deregulated environment, *Industry Applications*, IEEE Transactions on, Volumen 36, serie 3, paginas 893-898, 2000.
- [Edelman02] Edelman Adrian, Pronosticar la demanda Ejercicio de adivinación matemática o fundamento de la planificación operativa, Universidad de la República; Montevideo 2002.
- [Frantti+01] Tapio Frantti, Petri Mähönen, Fuzzy logic-based forecasting model *Engineering Applications of Artificial Intelligence*, Volume 14, Issue 2, April 2001, Pages 189-201
- [Funahashi+89] Funahashi, K., On the approximate realization of continuous mapping by neural networks, *Neural Networks*, 1989, v. 2, pp. 183-192.
- [Gaither+00] Autor Norman Gaither, Greg Frazier, Gabriel tr Sánchez García, *Administración de producción y operaciones*, Publicado por Cengage Learning Editores, 2000
- [Gil08] Annjulie Gil, “Pronóstico Del Deficit De Viviendas En El Estado Mérida A Través De Redes Neuronales Artificiales”, Proyecto de Grado, Universidad de los Andes Mérida, Venezuela, Abril 2008.

- [Hilera+95] Hilera, J.R y Martínez, V.J., Redes Neuronales artificiales. Fundamentos, modelos y aplicaciones, 1995, pp. 9.
- [Hokey+07] Min, Hokey; Yu, Wen-Bin 'Vincent', Collaborative planning, forecasting and replenishment: demand planning in supply chain management, *International Journal of Information Technology and Management*, v. 7, n. 1, 2007, pp. 4-20.
- [Hornik+89] Hornik, K., Stinchcombe, M. y White, H. , Multilayer feedforward networks are universal approximators, *Neural Networks*,v. 2, n. 5, pp. 359-366.
- [Jaramillo+05] M.A. Jaramillo, D. Carmona, E. González, J.A. Álvarez, Time series prediction with neural networks. Application to electric energy demand *Recent Advances*, 2005, pp 247-251.
- [Levis+05] A.A. Levis, L.G. Papageorgiou, Customer Demand Forecasting via Support Vector Regression Analysis, *Chemical Engineering Research and Design*, v. 83, n. 8, 2005, pp 1009-1018.
- [Mentzer+98] John Tom Mentzer, Carol C. Bienstock, *Gestión de Previsión de Ventas: Un enfoque de gestión de la demanda*, *Sales Forecasting Management: A Demand Management Approach*, Sage Publications, Inc; Har / Dis edición, 1998
- [Montaño02] Juan José Montaño Moreno, *Redes Neuronales Aplicadas al análisis de datos*, Tesis Doctoral, Palma de Mallorca, 2002
- [Morwitz+00] J. S., Morwitz V. and Kumar. V., "Sales forecasts for existing consumer products and services: Do purchase intentions contribute to accuracy?" *International Journal of Forecasting*, v. 16, 2000, pp. 383-397.
- [Nojek+02] Nojek, S. Britos, P. Rossi y Gracias Martinez, *Pronóstico de Ventas: Comparación de Predicción basada en redes neuronales versus método estadístico*, Centro de Ingeniería de Software a Ingeniería de Conocimiento- Argentina, 2002
- [Ofir87] Ofir, C., Raveh, A., "Forecasting demand in international markets: the case of correlated time series", *Journal of Forecasting*, v. 6 n. 1, 1987, pp. 41-92.
- [Padmakumari+99] K. Padmakumari, K. P. Mohandas, S. Thiruvengadam, Longterm distribution demand forecasting using neuro fuzzy computations, *International Journal of Electrical Power & Energy Systems*, Volume 21, Issue 5, June 1999, Pages 315-322

- [Palmer+05] Palmer Pol, A., Montañó Moreno, J.J , Calafat Far, A. Predicción Del Consumo de Fármacos A Partir De Redes Neuronales Artificiales Facultad de Psicología. Universidad de las Islas Baleares. España.
- [Parisi02] Antonio Parisi F. “Evaluación de Modelos de Redes Neuronales de predicción del signo de la variación del IPSA”, Estudios de Administración, v.9, n1, 2002.
- [Parker85] D.B. Parker, Learning-logic: Casting the cortex of the human brain in silicon Tech. Rep. TR-47, Center for Computational Research in Economics and Management Science, MIT, Cambridge, MA, 1985.
- [Parker87]D.B. Parker, Optimal algorithms for adaptive networks: Second order backpropagation, second order direct propagation and second order Hebbian learning IEEE 1st Int. Conf. on Neural Networks, vol.2, 1987, pp.593-600.
- [Petrovic+06] Dobrila Petrovic, Ying Xie y Keith Burnham, Fuzzy decision support system for demand forecasting with a learning mechanism, Fuzzy Sets and Systems, Volumen 157, Serie 12, Paginas 1713-1725, 2006
- [Pino02] R. Pino, D. De la Fuente,”Aplicación de Redes Neuronales Artificiales a la Previsión de Series Temporales No estacionarias o no Invertibles”, Universidad de Oviedo, Q “ UESTII’O, vol. 26, 3, 2002
- [Powell85] M.J.D. Powell, Radial basis functions for multivariate interpolation:A review IMA Conf. on Algorithms for the approximation of functions and Data, 1985, pp.143-167.
- [Rumelhart+86] D.E. Rumelhart, G.E. Hinton, R.J. Williams, Learning representations by back-propagating errors Nature (London), 323, 1986., pp.533-536.
- [Salazar+05] Maria Angélica Salazar, Mauricio Cabrera Ríos ,Pronostico de la demanda por medio de redes neuronales en la Industria de Telecomunicaciones, Maestría en Ingeniería de Sistemas, Universidad Autónoma de Nuevo León- UANL, México, 2005.
- [Serna03] Serna Martinez Paola, Proyección de la Demanda: Antecedentes, necesidad e importancia, Universidad Nacional de Colombia, 2003.
- [Srinivasan+95] Dipti Srinivasan Chang, C.S. Liew, A.C. , Demand forecasting using fuzzy neural computation, with special emphasis on weekend and public holiday forecasting, *Power Systems, IEEE Transactions on*, Volumen 10, Serie: 4, Paáginas: 1897-1903, 1995.

- [Tawfiq+99] Tawfiq Al-Saba and Ibrahim El-Amin, Artificial neural networks as applied to long-term demand forecasting , Artificial Intelligence in Engineering, Volumen 13, Serie 2, Paginas 189-197, 1999.
- [Thompson+98] Gary M. Thompson, Labor Scheduling, Part 1: Forecasting Demand, Cornell Hotel and Restaurant Administration Quarterly, Oct 1998; vol. 39: pp. 22 - 31.
- [Vera+07] Miguel Vera, Juan Bustamante, Modelo dinámico para la generación de pronóstico usando redes neuronales artificiales (RNA), Pag 130-142, marzo 2007
- [Werbos74] P. Werbos , Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Science Ph. D. dissertation, Harvard University, Cambridge, MA, 1974.
- [Werbos88] P. Werbos Generalization of backpropagation with application to a recurrent gas model, Neural Networks, vol.1, 1988, pp. 339-356.
- [Werbos89] P. Werbos, Backpropagation and neurocontrol: A review and prospectus Proc. Int. Joint Conf. on Neural Networks, Washington DC, June 1989.

# *Anexos*

# *Anexo A*

## *Ley general de salud*

EL CONGRESO DE LA REPUBLICA;

Ha dado la ley siguiente:

**Ley N° 26842**

**LEY GENERAL DE SALUD <sup>1</sup>**

**CONTENIDO**

**Capítulo III**

**De los Productos Farmacéuticos y Galénicos,  
y de los Recursos Terapéuticos Naturales**

**Artículo 52°.- Importación de productos farmacéuticos y galénicos**

Para la importación de productos farmacéuticos y galénicos, las Aduanas de la República, bajo responsabilidad, procederán al despacho de los mismos exigiendo únicamente una declaración jurada consignando lo siguiente:

a) El número de registro sanitario, o en su defecto la fecha de presentación de la solicitud correspondiente.

b) Identificación del embarque por lote de producción y fecha de vencimiento del medicamento; sin perjuicio de la documentación general requerida para las importaciones. Adicionalmente, tratándose de productos farmacéuticos derivados de sangre humana se exigirá, por cada lote de fabricación, un Certificado Analítico de negatividad de los virus de inmunodeficiencia humana y hepatitis vírales A y B.

La razón social y el registro unificado del importador o distribuidor general deberán figurar obligatoriamente por impresión o etiquetado en cada envase de venta al consumidor, conjuntamente con la fecha de vencimiento del medicamento.

La Autoridad de Salud de nivel nacional podrá autorizar provisionalmente, en casos debidamente calificados, la importación y venta, sin previo registro, de los productos comprendidos en el presente capítulo que correspondan, para usos medicinales de urgencia.

**Artículo 53°.- Importación de medicamentos no registrados con fines de  
Investigación**

Para fines exclusivos de investigación podrá autorizarse la importación, producción y uso de medicamentos no registrados, de conformidad con las disposiciones reglamentarias correspondientes.

**Artículo 55°.- Prohibición respecto a productos farmacéuticos**

Queda prohibida la fabricación, importación, tenencia, distribución y transferencia a cualquier título, de productos farmacéuticos y demás que señale el reglamento, contaminados, adulterados, falsificados, alterados y expirados.

---

<sup>1</sup>Fuente: <http://www.congreso.gob.pe/Leyes/26842.pdf>

Dirección General de Asuntos Ambientales

Los productos antes señalados deben ser inmediatamente retirados del mercado y destruidos apropiadamente, bajo responsabilidad.

#### **Artículo 56°.- Requisitos para fabricar o almacenar productos farmacéuticos**

Para desarrollar sus actividades, las personas naturales o jurídicas que se dedican a la fabricación o almacenamiento de productos farmacéuticos o ejecuten parte de los procesos que éstas comprenden, deben disponer de locales, equipos técnicos y de control adecuados y suficientes según lo establece el reglamento. Asimismo, deben ceñirse a las Buenas Prácticas de Manufactura, de Laboratorio y de Almacenamiento recomendadas por la Organización Mundial de la Salud o a las que dicte la Autoridad de Salud de nivel nacional, y a las normas técnicas de fabricación según corresponda.

La Autoridad de Salud de nivel nacional o a quien ésta delegue, verificará periódicamente el cumplimiento de lo establecido en la presente disposición.

#### **Artículo 57°.- Responsabilidad sobre la calidad de los productos**

El responsable de la calidad de los productos farmacéuticos es la empresa fabricante, si son elaborados en el país. Tratándose de productos elaborados en el extranjero la responsabilidad es del importador o distribuidor.

Cuando se trate de laboratorios encargados de elaborar productos por cuenta de terceros, ya sea en su totalidad o en alguna de las etapas del proceso de producción, la responsabilidad por la calidad del producto es asumida solidariamente por éste y por la empresa titular del Registro

Las distribuidoras y los establecimientos de venta al público de productos farmacéuticos, cada uno en su ámbito de comercialización, están obligados a conservar y vigilar el mantenimiento de su calidad hasta que sean recibidos por los usuarios, bajo responsabilidad.

#### **Artículo 58°.- Análisis cualitativos y cuantitativos de los productos Farmacéuticos**

Los productos farmacéuticos que se comercializan en el país y demás que correspondan, deben responder en sus análisis cualitativos y cuantitativos a la fórmula y composición declarada por el fabricante y autorizada para su fabricación y expedido al otorgarse el Registro Sanitario.

#### **Artículo 59°.- Control de calidad**

El control de calidad de los productos farmacéuticos y demás productos que correspondan es obligatorio, integral y permanente. Para garantizar su calidad, las empresas fabricantes, bajo responsabilidad, deben contar con un sistema de control de calidad, que abarque todos los aspectos del proceso de elaboración, desde las materias primas empleadas hasta los productos terminados.



### **Artículo 68°.- Clasificación de productos farmacéuticos**

La Autoridad de Salud de nivel nacional clasificará los productos farmacéuticos para efectos de su expendio en las siguientes categorías:

- a) De venta con presentación de receta especial numerada, que sólo pueden ser expendidos en farmacias y boticas, las que cumplirán con las exigencias que determinan los convenios internacionales en los que el Perú es parte, la ley de la materia y su reglamento.
- b) De venta bajo receta médica que sólo pueden ser expendidos en farmacias y boticas.
- c) De venta sin receta médica que se expenden exclusivamente en farmacias y boticas.
- d) De venta sin receta médica que pueden ser comercializados en establecimientos no farmacéuticos.

### **Artículo 69°.- Publicidad de productos farmacéuticos**

Pueden ser objetos de publicidad a través de medios que se encuentren al alcance del público en general, los productos farmacéuticos que cuentan con registro Sanitario en el país y autorizados para su venta sin receta médica. Además de lo dispuesto en las normas generales sobre publicidad en defensa del consumidor, el anuncio publicitario destinado al público en general, no deberá contener exageraciones sobre sus propiedades que puedan inducir a error al consumidor. Sólo por excepción y atendiendo a razones debidamente justificadas, la autoridad de Salud de nivel nacional podrá determinar los productos farmacéuticos de venta bajo receta médica que pueden ser objeto de publicidad a través de medios que se encuentren al alcance del público en general. En este caso la publicidad remitirá al consumidor a leer las instrucciones contenidas en el prospecto o inserto que acompaña al producto farmacéutico.

### **Plan de Ventas y Operación. (PVO o S&OP)**

De nada sirve un buen pronóstico si las áreas de suministro no están alineadas para entregar de manera oportuna los productos que se requieren. Para evitar esto se establece un proceso formal de Planeación de Ventas y Operación de la empresa llamado S&OP (Sales and Operations Planning) o también conocida como junta PVO (Planeación de Ventas y Operación).

De manera simple, el proceso S&OP consiste en una reunión mensual que a partir de los pronósticos e información de las áreas cercanas a la demanda se definen los objetivos y las actividades de forma consensuada. La junta se lleva a cabo después de haber realizado con diferentes responsables juntas previas de productos nuevos, productos activos y aspectos relativos sobre el suministro.

# ***Anexo B***

## ***Herramienta MATLAB***

## Lenguaje de programación: MATLAB

Entre las herramientas predefinidas que trae MATLAB, se encuentra el *Neuronal Network Toolbox*, que corresponde a una herramienta para el uso de redes neuronales artificiales y que contiene una variedad importante de redes, algoritmos de aprendizaje y funciones de transferencia.

La red neuronal back-propagation presenta una gran diversidad de opciones de configuración en el programa MATLAB dependiendo de la configuración en el aprendizaje y de la aplicación que se está desarrollando.

Los algoritmos de aprendizaje correspondiente a la red back-propagation y que pueden ser usados en él son las siguientes:

➤ *Newff*

Crea una red tipo Backpropagation, requiere que le sean especificados los siguientes parámetros

***newff*: (PR,[S1 S2...SNI],{TF1 TF2...TFNI},BTF,BLF,PF)**

PR : Rx2 Matriz de valores máximos y mínimos de cada uno de las R neuronas de entrada.

Si : Número de neuronas para cada una de las capas.

TFi : Función de transferencia a utilizar en cada una de las capas, por defecto utiliza *tansig*

BTF : Algoritmo de entrenamiento a utilizar, por defecto utiliza *trainlm*

BLF : Función de actualización de los pesos, por defecto utiliza *learnqdm*.

PF : Función para evaluar el desempeño de la red, por defecto utiliza *mse*.

➤ *Traingd*

Algoritmo de pasos descendientes, que actualiza pesos y ganancias variándolos en la dirección negativa del gradiente de la función del error. Es un algoritmo de aprendizaje muy lento, que requiere de la siguiente sintaxis:

- *net.trainParam.epochs*: Máximo número de iteraciones para obtener convergencia
- *net.trainParam.goal*: Error máximo permitido
- *net.trainParam.lr*: Rata de aprendizaje
- *net.trainParam.max\_fail*: Máximo número de fallas
- *net.trainParam.min\_grad*: Mínimo rendimiento del gradiente
- *net.trainParam.show*: Intervalo de visualización de los resultados
- *net.trainParam.time*: Máximo tiempo de entrenamiento en segundos

Con este algoritmo el aprendizaje de la red se detendrá si el número de iteraciones excede el comando *net.trainParam.epochs*, si se alcanzó el valor del error propuesto como meta, si la magnitud del gradiente es menor que *net.trainParam.min\_grad*, o si el tiempo d entrenamiento supera el valor de *net.trainParam.time*.

### ➤ ***Traingdm***

Equivale al algoritmo tradicional, más un nuevo coeficiente de momentum, que interviene en el proceso de actualización de los pesos. Si el error de la red en una iteración dada, excede el valor del error en la iteración anterior, en un valor mayor al definido por un radio de cobertura dado el que puede determinarse por medio de la función *max\_perf\_inc* y que está típicamente alrededor de 1.04, los nuevos pesos y ganancias son descartados y el coeficiente de momentum *mc* es fijado en cero.

La sintaxis de este algoritmo es igual a la utilizada para el algoritmo *traingd*, más un nuevo comando que permite modificar el coeficiente de momentum

- *net.trainParam.mc*: Valor fijado para el coeficiente de momentum

### ➤ ***Traingda***

Algoritmo de Gradiente Descendiente, que emplea una tasa de aprendizaje adaptiva durante el proceso de entrenamiento. La tasa de aprendizaje varía entre 0.01 y 1, una tasa de aprendizaje muy pequeña torna lento el aprendizaje, pero si se incrementa demasiado el aprendizaje puede tornarse inestable y crear divergencia, por esto la función *traingda* varía la tasa de aprendizaje tratando de sacar provecho de la inclinación del gradiente en cada momento; su gran desventaja es que los pesos iniciales varían muy poco así se encuentren distantes de los valores de convergencia. La sintaxis de este el algoritmo es la siguiente:

La sintaxis de este algoritmo se resume a continuación:

- *net.trainParam.epochs*: Máximo número de iteraciones para obtener convergencia
- *net.trainParam.goal*: Error máximo permitido
- *net.trainParam.lr*: Rata de aprendizaje inicial
- *net.trainParam.lr\_inc*: Porcentaje que incrementa la rata de aprendizaje cuando el error disminuye
- *net.trainParam.lr\_dec*: Porcentaje en que es decrementada la rata de aprendizaje cuando el error aumenta
- *net.trainParam.max\_fail*: Máximo número de fallas
- *net.trainParam.max\_perf\_inc*: Máximo incremento del rendimiento
- *net.trainParam.min\_grad*: Mínimo rendimiento del gradiente
- *net.trainParam.show*: Los resultados son visualizados siempre que transcurre este número de iteraciones.
- *net.trainParam.time*: Máximo tiempo de entrenamiento en segundos

### ➤ ***Trainrp***

Las redes multicapa, utilizan típicamente una función de transferencia sigmooidal (ver capítulo 1) en las capas ocultas, estas funciones comprimen un infinito rango de entradas, dentro de un finito rango de salidas, además se caracterizan porque su pendiente tendera cada vez más a cero, mientras más grande sea la entrada que se le presenta a la red, esto ocasiona problemas cuando

se usa un algoritmo de entrenamiento de pasos descendientes, porque el gradiente empieza a tomar valores muy pequeños y por lo tanto no habrán cambios representativos en los pesos y las ganancias, así se encuentren bastante lejos de sus valores óptimos. El propósito del algoritmo Backpropagation Resilient (RPROP) es eliminar este efecto en la magnitud de las derivadas parciales. En este algoritmo solamente el signo de la derivada es utilizado para determinar la dirección de actualización de los parámetros, la magnitud de las derivadas no tiene efecto en la actualización. La magnitud en el cambio de cada peso es determinada por separado; el valor del incremento de pesos y ganancias es determinado por el factor *delt\_inc*, así la derivada parcial del error con respecto a los pesos tenga el mismo signo durante dos iteraciones sucesivas; el valor de decremento está determinado por el factor *delt\_dec* así la derivada del error con respecto a los pesos haya cambiado de signo con respecto a la anterior iteración; si la derivada es cero, entonces el valor actualizado se conserva; si los pesos continúan cambiando en la misma dirección durante varias iteraciones, la magnitud de cambios de los pesos se decrementa.

La sintaxis de este algoritmo se resume a continuación:

- *net.trainParam.epochs*: Máximo número de iteraciones del entrenamiento
- *net.trainParam.show*: Intervalo de visualización de los resultados
- *net.trainParam.goal*: Error deseado
- *net.trainParam.time=inf*: Máximo tiempo de entrenamiento en segundos
- *net.trainParam.min\_grad*: Mínimo rendimiento del gradiente
- *net.trainParam.max\_fail*: Máximo número de fallas
- *net.trainParam.lr*: Rata de aprendizaje
- *net.trainParam.delt\_inc*: Incremento en la actualización de pesos
- *net.trainParam.delt\_dec*: Decremento en la actualización de pesos
- *net.trainParam.delta0*: Incremento inicial en la actualización de pesos
- *net.trainParam.deltamax*: Máximo cambio en los pesos

#### ➤ **Trainbfg**

Algoritmo alternativo que emplea la técnica del gradiente conjugado, su expresión matemática se deriva del método de Newton, con la ventaja de que no es necesario computar las segundas derivadas; este algoritmo requiere mas capacidad de almacenamiento que el algoritmo tradicional, pero generalmente converge en menos iteraciones. Requiere de un cálculo aproximado de la matriz Hessiana, la cual es de dimensiones  $n^2 \times n^2$ , donde n la cantidad de pesos y ganancias de la red; para redes que involucren una gran cantidad de parámetros es preferible emplear el algoritmo trainrp.

- *net.trainParam.epochs*: Máximo número de iteraciones del entrenamiento
- *net.trainParam.show*: Número de iteraciones entre las cuales se muestran resultados
- *net.trainParam.goal*: Error deseado
- *net.trainParam.time=inf*: Máximo tiempo de entrenamiento en segundos
- *net.trainParam.min\_grad*: Mínimo rendimiento del gradiente

- *net.trainParam.max\_fail=5*: Máximo número de fallas
- *net.trainParam.searchFcn*: Nombre de la rutina de búsqueda lineal a utilizar.
- *net.trainParam.scal\_tol*: Se divide entre el valor de Delta para determinar la tolerancia para la búsqueda lineal.
- *net.trainParam.alpha*: Factor de escala que determina una reducción suficiente en el desempeño.
- *net.trainParam.beta*: Factor de escala que determina un tamaño de paso suficientemente grande.
- *net.trainParam.delta*: Tamaño de paso inicial en el intervalo de localización de paso.
- *net.trainParam.gama*: Parámetro para evitar pequeñas reducciones en el desempeño.
- *net.trainParam.low\_lim*: Límite inferior en el cambio del tamaño del paso.
- *net.trainParam.up\_lim*: Límite superior en el cambio del tamaño del paso.
- *net.trainParam.maxstep*: Máximo longitud de paso.
- *net.trainParam.minstep*: Mínima longitud de paso; por defecto es 1.0e-6
- *net.trainParam.bmax*: Máximo tamaño de paso.

#### ➤ **Trainlm**

Algoritmo que actualiza los pesos y las ganancias de acuerdo a la optimización de Levenberg-Marquardt. Es el algoritmo más rápido para redes Backpropagation; tiene la desventaja de requerir de un set de entrenamiento lo más estándar posible, pues de otra forma solo aproximará correctamente valores que se encuentren dentro de los patrones de aprendizaje. Si el set de entrenamiento es muy extenso, se recomienda reducir el Jacobiano.

La sintaxis de este algoritmo es la siguiente:

- *net.trainParam.epochs*: Máximo número de iteraciones del entrenamiento
- *net.trainParam.goal*: Error deseado
- *net.trainParam.lr*: Rata de aprendizaje
- *net.trainParam.max\_fail*: Máximo número de veces que falla el valor de Mu
- *net.trainParam.mem\_reduc*: Factor de fraccionamiento de Jacobiano para ahorrar memoria
- *net.trainParam.min\_grad*: Mínimo rendimiento del gradiente
- *net.trainParam.show*: Intervalo de visualización de los resultados.
- *net.trainParam.time*: Máximo tiempo de entrenamiento en segundos
- *tr.mu*: Valor del Mu adaptivo

# *Anexo C*

*Datos históricos de los productos*

*RG y CH*

## Datos Históricos del producto RG

El producto RG es el segundo producto que será pronosticado, por lo tanto a continuación se darán a conocer los datos a utilizar para su proceso de pronóstico.

- **Datos totales:** En la siguiente tabla se muestra los datos históricos utilizados para el producto RG, los cuales son 51 y corresponden a 5 años (2006,2007, 2008,2009 y el primer trimestre del 2010).

	i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y	
2006	1	1	9.14	0	0	1	8.35	0	0	1	8,671	Datos para la fase de entrenamiento
	2	2	9.99	0	0	1	7.56	0	0	1	6,210	
	3	3	9.16	1	2	1	7.98	1	1	0	6,635	
	4	4	9.56	2	5	1	7.75	1	2	0	12,708	
	5	5	10.72	0	0	1	8.05	1	1	1	8,636	
	6	6	10.54	2	3	0	8.12	1	4	0	9,122	
	7	7	9.83	2	4	0	7.98	0	0	1	10,815	
	8	8	9.70	1	3	1	8.23	1	3	1	10,399	
	9	9	9.82	0	0	1	7.34	0	0	1	9,865	
	10	10	9.60	0	0	0	7.34	1	4	0	7,732	
	11	11	9.72	1	4	1	7.23	2	5	1	9,967	
	12	12	9.59	0	0	1	7.67	0	0	1	6,167	
2007	13	1	9.88	1	4	1	7.95	0	0	0	12,003	
	14	2	10.01	0	0	0	7.68	2	3	1	4,151	
	15	3	9.99	0	0	1	7.99	1	2	1	5,346	
	16	4	9.86	0	0	1	8.07	0	0	1	6,245	
	17	5	10.87	1	7	1	8.26	0	0	1	15,226	
	18	6	11.43	2	2	0	8.16	2	1	1	11,475	
	19	7	11.84	1	2	1	9.31	0	0	1	11,845	
	20	8	11.80	2	6	1	8.47	0	0	1	16,643	
	21	9	12.08	0	0	0	9.28	2	3	1	2,901	
	22	10	12.57	1	1	1	8.72	1	3	1	8,069	
	23	11	12.07	1	5	0	8.91	0	0	1	11,702	
	24	12	12.46	0	0	1	8.85	1	2	1	5,421	
2008	25	1	12.39	0	0	1	9.51	0	0	1	8,467	
	26	2	12.43	1	3	0	7.73	2	2	1	7,123	
	27	3	12.39	2	1	0	8.13	3	5	0	6,236	
	28	4	12.32	1	1	0	8.92	2	3	1	3,185	
	29	5	12.51	1	1	1	9.15	0	0	0	7,943	
	30	6	12.46	0	0	1	8.29	1	1	0	7,721	
	31	7	12.33	2	2	1	8.95	0	0	1	9,979	
	32	8	12.24	1	1	0	7.39	0	0	1	9,512	
	33	9	12.23	0	0	1	7.64	0	0	0	8,726	
	34	10	12.12	0	0	1	7.53	0	0	1	8,327	
	35	11	12.45	0	0	1	7.82	1	3	1	6,279	
	36	12	12.28	1	1	0	7.63	0	0	1	8,242	
2009	37	1	13.37	1	2	0	7.90	2	4	0	7,876	
	38	2	14.27	0	0	1	8.12	1	2	1	6,389	
	39	3	13.66	1	3	0	7.24	2	6	1	2,090	
	40	4	14.41	2	1	1	9.15	2	5	0	7,640	
	41	5	14.48	2	6	1	11.25	0	0	1	11,812	
	42	6	14.46	0	0	1	9.08	1	3	0	4,768	
	43	7	15.55	0	0	0	9.37	2	4	0	3,297	
	44	8	16.15	0	0	1	9.56	1	4	1	4,909	
	45	9	14.70	1	1	0	9.45	1	3	0	6,031	
2010	46	10	14.25	1	2	1	8.99	1	1	1	9,244	
	47	11	14.46	1	4	1	8.76	0	0	1	9,757	
	48	12	13.22	0	0	0	8.75	2	6	1	5,817	
	49	1	15.39	1	3	1	9.03	2	4	0	7,661	
	50	2	12.82	0	0	1	8.33	1	4	1	6,775	
	51	3	14.14	1	1	0	8.87	1	4	0	5,646	

*Datos totales del producto RG*



- **Datos de entrenamiento:** En la tabla 3.2 se muestra los datos que serán usados para el entrenamiento de la red neuronal, la cual consta de 45 instancias.

i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
1	1	9.14	0	0	1	8.35	0	0	1	8,671
2	2	9.99	0	0	1	7.56	0	0	1	6,210
3	3	9.16	1	2	1	7.98	1	1	0	6,635
4	4	9.56	2	5	1	7.75	1	2	0	12,708
5	5	10.72	0	0	1	8.05	1	1	1	8,636
6	6	10.54	2	3	0	8.12	1	4	0	9,122
7	7	9.83	2	4	0	7.98	0	0	1	10,815
8	8	9.70	1	3	1	8.23	1	3	1	10,399
9	9	9.82	0	0	1	7.34	0	0	1	9,865
10	10	9.60	0	0	0	7.34	1	4	0	7,732
11	11	9.72	1	4	1	7.23	2	5	1	9,967
12	12	9.59	0	0	1	7.67	0	0	1	6,167
13	1	9.88	1	4	1	7.95	0	0	0	12,003
14	2	10.01	0	0	0	7.68	2	3	1	4,151
15	3	9.99	0	0	1	7.99	1	2	1	5,346
16	4	9.86	0	0	1	8.07	0	0	1	6,245
17	5	10.87	1	7	1	8.26	0	0	1	15,226
18	6	11.43	2	2	0	8.16	2	1	1	11,475
19	7	11.84	1	2	1	9.31	0	0	1	11,845
20	8	11.80	2	6	1	8.47	0	0	1	16,643
21	9	12.08	0	0	0	9.28	2	3	1	2,901
22	10	12.57	1	1	1	8.72	1	3	1	8,069
23	11	12.07	1	5	0	8.91	0	0	1	11,702
24	12	12.46	0	0	1	8.85	1	2	1	5,421
25	1	12.39	0	0	1	9.51	0	0	1	8,467
26	2	12.43	1	3	0	7.73	2	2	1	7,123
27	3	12.39	2	1	0	8.13	3	5	0	6,236
28	4	12.32	1	1	0	8.92	2	3	1	3,185
29	5	12.51	1	1	1	9.15	0	0	0	7,943
30	6	12.46	0	0	1	8.29	1	1	0	7,721
31	7	12.33	2	2	1	8.95	0	0	1	9,979
32	8	12.24	1	1	0	7.39	0	0	1	9,512
33	9	12.23	0	0	1	7.64	0	0	0	8,726
34	10	12.12	0	0	1	7.53	0	0	1	8,327
35	11	12.45	0	0	1	7.82	1	3	1	6,279
36	12	12.28	1	1	0	7.63	0	0	1	8,242
37	1	13.37	1	2	0	7.90	2	4	0	7,876
38	2	14.27	0	0	1	8.12	1	2	1	6,389
39	3	13.66	1	3	0	7.24	2	6	1	2,090
40	4	14.41	2	1	1	9.15	2	5	0	7,640
41	5	14.48	2	6	1	11.25	0	0	1	11,812
42	6	14.46	0	0	1	9.08	1	3	0	4,768
43	7	15.55	0	0	0	9.37	2	4	0	3,297
44	8	16.15	0	0	1	9.56	1	4	1	4,909
45	9	14.70	1	1	0	9.45	1	3	0	6,031

*Datos de entrenamiento del producto RG*

- **Normalización de datos:** La normalización de datos se ha llevado a cabo a partir de la división de todos los datos de una variable entre el mayor de ellos.

$$D_n = D_i / MD$$

- $D_n$ = Dato Normalizado
- $D_i$  = Dato i de la variable de entrada.
- $MD$ =Máximo valor de la variable de entrada

De acuerdo a la formula anterior la tabla 3.3 muestra los datos de entrenamiento normalizados.

Datos normalizados										
i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
1	0.0833	0.5658	0.0000	0.0000	1.0000	0.7422	0.0000	0.0000	1.0000	0.5210
2	0.1667	0.6184	0.0000	0.0000	1.0000	0.6720	0.0000	0.0000	1.0000	0.3731
3	0.2500	0.5670	0.5000	0.2857	1.0000	0.7093	0.3333	0.1667	0.0000	0.3987
4	0.3333	0.5918	1.0000	0.7143	1.0000	0.6889	0.3333	0.3333	0.0000	0.7636
5	0.4167	0.6636	0.0000	0.0000	1.0000	0.7156	0.3333	0.1667	1.0000	0.5189
6	0.5000	0.6524	1.0000	0.4286	0.0000	0.7218	0.3333	0.6667	0.0000	0.5481
7	0.5833	0.6085	1.0000	0.5714	0.0000	0.7093	0.0000	0.0000	1.0000	0.6498
8	0.6667	0.6005	0.5000	0.4286	1.0000	0.7316	0.3333	0.5000	1.0000	0.6248
9	0.7500	0.6079	0.0000	0.0000	1.0000	0.6524	0.0000	0.0000	1.0000	0.5927
10	0.8333	0.5943	0.0000	0.0000	0.0000	0.6524	0.3333	0.6667	0.0000	0.4646
11	0.9167	0.6017	0.5000	0.5714	1.0000	0.6427	0.6667	0.8333	1.0000	0.5989
12	1.0000	0.5936	0.0000	0.0000	1.0000	0.6818	0.0000	0.0000	1.0000	0.3705
13	0.0833	0.6116	0.5000	0.5714	1.0000	0.7067	0.0000	0.0000	0.0000	0.7212
14	0.1667	0.6196	0.0000	0.0000	0.0000	0.6827	0.6667	0.5000	1.0000	0.2494
15	0.2500	0.6184	0.5000	1.0000	1.0000	0.7102	0.3333	0.3333	1.0000	0.3212
16	0.3333	0.6104	0.0000	0.0000	1.0000	0.7173	0.0000	0.0000	1.0000	0.3752
17	0.4167	0.6729	0.5000	1.0000	1.0000	0.7342	0.0000	0.0000	1.0000	0.9149
18	0.5000	0.7075	1.0000	0.2857	0.0000	0.7253	0.6667	0.1667	1.0000	0.6895
19	0.5833	0.7329	0.5000	0.2857	1.0000	0.8276	0.0000	0.0000	1.0000	0.7117
20	0.6667	0.7304	1.0000	0.8571	1.0000	0.7529	0.0000	0.0000	1.0000	1.0000
21	0.7500	0.7478	0.0000	0.0000	0.0000	0.8249	0.6667	0.5000	1.0000	0.1743
22	0.8333	0.7781	0.5000	0.1429	1.0000	0.7751	0.3333	0.5000	1.0000	0.4848
23	0.9167	0.7472	0.5000	0.7143	0.0000	0.7920	0.0000	0.0000	1.0000	0.7031
24	1.0000	0.7713	0.0000	0.0000	1.0000	0.7867	0.3333	0.3333	1.0000	0.3257
25	0.0833	0.7670	0.0000	0.0000	1.0000	0.8453	0.0000	0.0000	1.0000	0.5087
26	0.1667	0.7694	0.5000	0.4286	0.0000	0.6871	0.6667	0.3333	1.0000	0.4280
27	0.2500	0.7670	1.0000	0.1429	0.0000	0.7227	1.0000	0.8333	0.0000	0.3747
28	0.3333	0.7626	0.5000	0.1429	0.0000	0.7929	0.6667	0.5000	1.0000	0.1914
29	0.4167	0.7744	0.5000	0.1429	1.0000	0.8133	0.0000	0.0000	0.0000	0.4773
30	0.5000	0.7713	0.0000	0.0000	1.0000	0.7369	0.3333	0.1667	0.0000	0.4639
31	0.5833	0.7633	1.0000	0.2857	1.0000	0.7956	0.0000	0.0000	1.0000	0.5996
32	0.6667	0.7577	0.5000	0.1429	0.0000	0.6569	0.0000	0.0000	1.0000	0.5715
33	0.7500	0.7571	0.0000	0.0000	1.0000	0.6791	0.0000	0.0000	0.0000	0.5243
34	0.8333	0.7503	0.0000	0.0000	1.0000	0.6693	0.0000	0.0000	1.0000	0.5003
35	0.9167	0.7707	0.0000	0.0000	1.0000	0.6951	0.3333	0.5000	1.0000	0.3773
36	1.0000	0.7602	0.5000	0.1429	0.0000	0.6782	0.0000	0.0000	1.0000	0.4952
37	0.0833	0.8276	0.5000	0.2857	0.0000	0.7022	0.6667	0.6667	0.0000	0.4732
38	0.1667	0.8833	0.0000	0.0000	1.0000	0.7218	0.3333	0.3333	1.0000	0.3839
39	0.2500	0.8458	0.5000	0.4286	0.0000	0.6436	0.6667	1.0000	1.0000	0.1256
40	0.3333	0.8918	1.0000	0.1429	1.0000	0.8133	0.6667	0.8333	0.0000	0.4591
41	0.4167	0.8963	1.0000	0.8571	1.0000	1.0000	0.0000	0.0000	1.0000	0.7097
42	0.5000	0.8954	0.0000	0.0000	1.0000	0.8071	0.3333	0.5000	0.0000	0.2865
43	0.5833	0.9627	0.0000	0.0000	0.0000	0.8329	0.6667	0.6667	0.0000	0.1981
44	0.6667	1.0000	0.0000	0.0000	1.0000	0.8498	0.3333	0.6667	1.0000	0.2950
45	0.7500	0.9100	0.5000	0.1429	0.0000	0.8400	0.3333	0.5000	0.0000	0.3624

*Datos de entrenamiento normalizados del producto RG*

- **Datos de validación:** En la tabla 3.4 se muestra los datos que serán usados para validación de la red neuronal, la cual consta de 12 instancias.

i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
46	10	14.25	1	2	1	8.99	1	1	1	9,244
47	11	14.46	1	4	1	8.76	0	0	1	9,757
48	12	13.22	0	0	0	8.75	2	6	1	5,817
49	1	15.39	1	3	1	9.03	2	4	0	7,661
50	2	12.82	0	0	1	8.33	1	4	1	6,775
51	3	14.14	1	1	0	8.87	1	4	0	5,646

*Datos de validación del producto RG*

- **Normalización de Datos:** Los datos serán normalizados con la misma ecuación mostrada en el entrenamiento. Los datos normalizados se muestran en la siguiente tabla

Datos normalizados										
i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
46	0.8333	0.8819	0.5000	0.2857	1.0000	0.7991	0.3333	0.1667	1.0000	0.5554
47	0.9167	0.8949	0.5000	0.5714	1.0000	0.7787	0.0000	0.0000	1.0000	0.5863
48	1.0000	0.8181	0.0000	0.0000	0.0000	0.7778	0.6667	1.0000	1.0000	0.3495
49	0.0833	0.9529	0.5000	0.4286	1.0000	0.8027	0.6667	0.6667	0.0000	0.4603
50	0.1667	0.7938	0.0000	0.0000	1.0000	0.7404	0.3333	0.6667	1.0000	0.4071
51	0.2500	0.8751	0.5000	0.1429	0.0000	0.7884	0.3333	0.6667	0.0000	0.3392

*Datos de entrenamiento normalizados del producto RG*

## Datos históricos del producto CH

El producto CH es el tercer producto a ser pronosticado, a continuación se conocerán los datos a utilizar para su proceso de pronóstico.

- **Datos totales:** La siguiente tabla muestra los datos históricos utilizados para el producto CH, los cuales son 36 y corresponden a 3 años (2006,2007 y 2008).

	i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
2006	1	1	5,28	2	4	1	4,51	0	0	1	15.991
	2	2	5,24	1	1	1	4,43	0	0	1	13.854
	3	3	5,16	1	1	0	4,69	1	1	0	13.835
	4	4	5,17	2	7	1	4,92	0	0	1	23.202
	5	5	5,14	1	1	0	5,02	1	1	1	12.768
	6	6	5,94	0	0	1	5,23	0	0	0	13.543
	7	7	5,45	0	0	0	5,11	1	6	0	7.524
	8	8	5,13	1	2	1	4,68	1	2	1	14.353
	9	9	5,23	1	1	0	4,83	1	1	1	12.195
	10	10	6,13	0	0	1	5,18	1	4	0	12.384
	11	11	5,14	1	2	0	4,89	2	1	1	14.813
	12	12	5,21	1	3	0	5,13	0	0	1	13.888
2007	13	1	5,24	1	4	1	5,15	0	0	1	15.520
	14	2	5,25	2	5	0	4,95	1	2	0	19.482
	15	3	5,46	1	2	0	5,01	0	0	1	11.082
	16	4	5,37	0	0	1	4,59	0	0	0	13.918
	17	5	5,44	0	0	1	4,69	0	0	1	14.102
	18	6	5,62	1	3	0	4,87	0	0	1	15.776
	19	7	5,84	0	0	0	4,91	0	0	1	9.073
	20	8	5,88	2	3	1	5,01	0	0	1	17.090
	21	9	6,03	0	0	0	5,26	1	5	0	9.092
	22	10	6,21	0	0	1	5,31	1	3	0	11.909
	23	11	6,09	1	5	0	5,11	0	0	1	15.101
	24	12	6,19	1	1	1	4,48	0	0	1	12.730
2008	25	1	6,16	0	0	1	5,46	0	0	0	15.879
	26	2	6,19	0	0	0	5,12	0	0	1	13.754
	27	3	6,15	0	0	1	5,15	1	1	0	13.468
	28	4	6,14	0	0	1	5,19	1	2	0	13.607
	29	5	6,20	1	3	0	4,82	1	3	0	13.136
	30	6	6,16	0	0	1	4,82	1	1	0	12.788
	31	7	6,11	2	2	0	4,91	0	0	1	15.034
	32	8	6,10	1	2	0	4,92	1	2	0	14.294
	33	9	6,06	0	0	0	5,06	0	0	0	15.707
	34	10	6,07	1	2	1	4,49	1	4	1	13.075
	35	11	6,12	1	3	0	4,97	0	0	1	16.196
	36	12	6,12	1	2	0	4,99	0	0	0	15.477

Datos para la fase de entrenamiento

Datos para la fase de validación

*Datos totales del producto CH*

- **Datos de entrenamiento:** En la siguiente tabla se muestra los datos que serán usados para el entrenamiento de la red neuronal, la cual consta de 30 instancias correspondientes a todos meses de los años 2006 y 2007 y al primer semestre del 2008.

	i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
2006	1	1	5,28	2	4	1	4,51	0	0	1	15.991
	2	2	5,24	1	1	1	4,43	0	0	1	13.854
	3	3	5,16	1	1	0	4,69	1	1	0	13.835
	4	4	5,17	2	7	1	4,92	0	0	1	23.202
	5	5	5,14	1	1	0	5,02	1	1	1	12.768
	6	6	5,94	0	0	1	5,23	0	0	0	13.543
	7	7	5,45	0	0	0	5,11	1	6	0	7.524
	8	8	5,13	1	2	1	4,68	1	2	1	14.353
	9	9	5,23	1	1	0	4,83	1	1	1	12.195
	10	10	6,13	0	0	1	5,18	1	4	0	12.384
	11	11	5,14	1	2	0	4,89	2	1	1	14.813
	12	12	5,21	1	3	0	5,13	0	0	1	13.888
2007	13	1	5,24	1	4	1	5,15	0	0	1	15.520
	14	2	5,25	2	5	0	4,95	1	2	0	19.482
	15	3	5,46	1	2	0	5,01	0	0	1	11.082
	16	4	5,37	0	0	1	4,59	0	0	0	13.918
	17	5	5,44	0	0	1	4,69	0	0	1	14.102
	18	6	5,62	1	3	0	4,87	0	0	1	15.776
	19	7	5,84	0	0	0	4,91	0	0	1	9.073
	20	8	5,88	2	3	1	5,01	0	0	1	17.090
	21	9	6,03	0	0	0	5,26	1	5	0	9.092
	22	10	6,21	0	0	1	5,31	1	3	0	11.909
	23	11	6,09	1	5	0	5,11	0	0	1	15.101
	24	12	6,19	1	1	1	4,48	0	0	1	12.730
2008	25	1	6,16	0	0	1	5,46	0	0	0	15.879
	26	2	6,19	0	0	0	5,12	0	0	1	13.754
	27	3	6,15	0	0	1	5,15	1	1	0	13.468
	28	4	6,14	0	0	1	5,19	1	2	0	13.607
	29	5	6,20	1	3	0	4,82	1	3	0	13.136
	30	6	6,16	0	0	1	4,82	1	1	0	12.788

*Datos de entrenamiento del producto CH*

• **Normalización de los datos de entrenamiento**

La normalización de datos se ha llevado a cabo a partir de la división de todos los datos de una variable entre el mayor de ellos.

$$D_n = D_i / MD$$

- D<sub>n</sub>= Dato Normalizado
- D<sub>i</sub> = Dato i de la variable de entrada.
- MD=Máximo valor de la variable de entrada

De acuerdo a la formula anterior la tabla 3.8 muestra los datos de entrenamiento normalizados.

i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
1	0,0833	0,8502	1,0000	0,5714	1,0000	0,8260	0,0000	0,0000	1,0000	0,6892
2	0,1667	0,8438	0,5000	0,1429	1,0000	0,8114	0,0000	0,0000	1,0000	0,5971
3	0,2500	0,8309	0,5000	0,1429	0,0000	0,8590	0,5000	0,1429	0,0000	0,5963
4	0,3333	0,8325	1,0000	1,0000	1,0000	0,9011	0,0000	0,0000	1,0000	1,0000
5	0,4167	0,8277	0,5000	0,1429	0,0000	0,9194	0,5000	0,1429	1,0000	0,5503
6	0,5000	0,9565	0,0000	0,0000	1,0000	0,9579	0,0000	0,0000	0,0000	0,5837
7	0,5833	0,8776	0,0000	0,0000	0,0000	0,9359	0,5000	0,8571	0,0000	0,3243
8	0,6667	0,8261	0,5000	0,2857	1,0000	0,8571	0,5000	0,2857	1,0000	0,6186
9	0,7500	0,8422	0,5000	0,1429	0,0000	0,8846	0,5000	0,1429	1,0000	0,5256
10	0,8333	0,9871	0,0000	0,0000	1,0000	0,9487	0,5000	0,5714	0,0000	0,5337
11	0,9167	0,8277	0,5000	0,2857	0,0000	0,8956	1,0000	0,1429	1,0000	0,6384
12	1,0000	0,8390	0,5000	0,4286	0,0000	0,9396	0,0000	0,0000	1,0000	0,5986
13	0,0833	0,8438	0,5000	0,5714	1,0000	0,9432	0,0000	0,0000	1,0000	0,6689
14	0,1667	0,8454	1,0000	0,7143	0,0000	0,9066	0,5000	0,2857	0,0000	0,8397
15	0,2500	0,8792	0,5000	0,2857	0,0000	0,9176	0,0000	0,0000	1,0000	0,4776
16	0,3333	0,8647	0,0000	0,0000	1,0000	0,8407	0,0000	0,0000	0,0000	0,5999
17	0,4167	0,8760	0,0000	0,0000	1,0000	0,8590	0,0000	0,0000	1,0000	0,6078
18	0,5000	0,9050	0,5000	0,4286	0,0000	0,8919	0,0000	0,0000	1,0000	0,6799
19	0,5833	0,9404	0,0000	0,0000	0,0000	0,8993	0,0000	0,0000	1,0000	0,3910
20	0,6667	0,9469	1,0000	0,4286	1,0000	0,9176	0,0000	0,0000	1,0000	0,7366
21	0,7500	0,9710	0,0000	0,0000	0,0000	0,9634	0,5000	0,7143	0,0000	0,3919
22	0,8333	1,0000	0,0000	0,0000	1,0000	0,9725	0,5000	0,4286	0,0000	0,5133
23	0,9167	0,9807	0,5000	0,7143	0,0000	0,9359	0,0000	0,0000	1,0000	0,6508
24	1,0000	0,9968	0,5000	0,1429	1,0000	0,8205	0,0000	0,0000	1,0000	0,5487
25	0,0833	0,9919	0,0000	0,0000	1,0000	1,0000	0,0000	0,0000	0,0000	0,6844
26	0,1667	0,9968	0,0000	0,0000	0,0000	0,9377	0,0000	0,0000	1,0000	0,5928
27	0,2500	0,9903	0,0000	0,0000	1,0000	0,9432	0,5000	0,1429	0,0000	0,5805
28	0,3333	0,9887	0,0000	0,0000	1,0000	0,9505	0,5000	0,2857	0,0000	0,5865
29	0,4167	0,9984	0,5000	0,4286	0,0000	0,8828	0,5000	0,4286	0,0000	0,5662
30	0,5000	0,9919	0,0000	0,0000	1,0000	0,8828	0,5000	0,1429	0,0000	0,5512

*Datos de entrenamiento normalizados del producto CH*

- **Datos de validación:** En la siguiente tabla se muestra los datos que serán usados para validación de la red neuronal, la cual consta de 6 instancias correspondientes al primer semestre del año 2008.

i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
31	7	6,11	2	2	0	4,91	0	0	1	15.034
32	8	6,10	1	2	0	4,92	1	2	0	14.294
33	9	6,06	0	0	0	5,06	0	0	0	15.707
34	10	6,07	1	2	1	4,49	1	4	1	13.075
35	11	6,12	1	3	0	4,97	0	0	1	16.196
36	12	6,12	1	2	0	4,99	0	0	0	15.477

*Datos de validación del producto CH*

- **Normalización de los datos de validación:** Los datos serán normalizados con la misma ecuación mostrada en el entrenamiento. Los datos normalizados se muestran en la siguiente tabla.

i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
31	0,5833	0,9839	1,0000	0,2857	0,0000	0,8993	0,0000	0,0000	1,0000	0,6480
32	0,6667	0,9823	0,5000	0,2857	0,0000	0,9011	0,5000	0,2857	0,0000	0,6161
33	0,7500	0,9758	0,0000	0,0000	0,0000	0,9267	0,0000	0,0000	0,0000	0,6770
34	0,8333	0,9775	0,5000	0,2857	1,0000	0,8223	0,5000	0,5714	1,0000	0,5635
35	0,9167	0,9855	0,5000	0,4286	0,0000	0,9103	0,0000	0,0000	1,0000	0,6980
36	1,0000	0,9855	0,5000	0,2857	0,0000	0,9139	0,0000	0,0000	0,0000	0,6671

*Datos normalizados de validación del producto CH*

# *Anexo D*

## *Entrenamiento y validación de la RNA*



## Archivos .M

- **Archivos .M del producto DF**

Los siguientes archivos contienen las matrices que serán utilizadas en el Neural Network para el entrenamiento y validación de la Red Neuronal que pronostique la cantidad demandada del producto DF.

```
C:\MATLAB6p5\work\Entradas_Ent_DONAFAN.m
File Edit Text Window Help
Entradas_Ent_DF = [
1 0.0833 0.1667 0.2500 0.3333 0.4167 0.5000 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000 0.0833 0.1667 0.2500 0.3333 0.4167 0.5000 0.5833 0.66
2 0.5678 0.6799 0.6845 0.7513 0.7302 0.7856 0.7424 0.7563 0.7495 0.7599 0.7508 0.7504 0.7811 0.7837 0.7733 0.7783 0.7751 0.8043 0.8176 0.81
3 1.0000 0.0000 0.5000 0.0000 0.0000 0.0000 0.0000 0.5000 0.0000 0.0000 0.0000 1.0000 0.5000 0.0000 0.5000 0.0000 0.0000 0.0000 0.0000 0.00
4 0.5714 0.0000 1.0000 0.0000 0.0000 0.0000 0.0000 0.4286 0.0000 0.0000 0.0000 0.7143 0.5714 0.0000 1.0000 0.0000 0.0000 0.0000 0.0000 0.0000 0.00
5 1.0000 0.0000 1.0000 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000 1.0000 0.0000 0.0000 1.0000 0.0000 1.0000 0.0000 1.0000 0.0000 1.0000 0.0000 0.00
6 0.6978 0.7360 0.7983 0.6855 0.8863 0.8415 0.9341 0.7023 0.8341 0.6849 0.7725 0.8660 0.9101 0.9251 0.9769 0.8993 0.8641 0.9739 0.9545 0.90
7 0.0000 0.0000 0.5000 0.0000 0.5000 0.0000 0.0000 0.5000 0.0000 0.5000 1.0000 0.0000 0.0000 0.0000 0.0000 0.0000 1.0000 0.0000 0.0000 0.0000 0.00
8 0.0000 0.0000 0.1429 0.0000 0.2857 0.0000 0.0000 0.4286 0.0000 0.5714 0.7143 0.0000 0.0000 0.0000 0.0000 0.0000 0.0000 0.5714 0.0000 0.0000 0.00
9 0.0000 0.0000 0.0000 0.0000 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000 1.0000 1.0000 0.0000 0.0000 0.0000 1.0000 1.0000 1.0000 1.0000 0.0000 0.00
10 0.0000 0.0000 0.0000 0.0000 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000 1.0000 1.0000 0.0000 0.0000 0.0000 1.0000 1.0000 1.0000 1.0000 0.0000 0.00
11
```

*Matriz de entradas para el entrenamiento del producto DF  
Matriz de 9x39*

```
C:\MATLAB6p5\work\Target_Ent_DONAFAN.m
File Edit Text Window Help
Target_Ent_DF = [
1 0.9968 0.9503 0.9872 0.2904 0.4480 0.5908 0.6305 0.4822 0.5549 0.5166 0.6380 0.5838 0.8209 0.7891 0.9961 0.5913 0.8033 0.4629 0.3286 0.68
2
3
4
5
```

*Matriz de salidas(targets) para el entrenamiento del producto DF  
Matriz de 1x 39*

```
C:\MATLAB6p5\work\Entradas_Val_DONAFAN.m
File Edit Text Window Help
Entradas_Val_DF=[
1 0.3333 0.4167 0.5000 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000 0.0833 0.1667 0.2500
2 0.9336 0.9277 0.9398 0.9353 0.9356 0.9290 0.9218 0.9388 0.9772 0.9867 0.9833 0.9734
3 0.0000 0.0000 0.5000 0.5000 0.5000 0.0000 0.0000 1.0000 0.5000 0.5000 1.0000
4 0.0000 0.0000 0.4286 0.2857 0.2857 0.0000 0.0000 0.2857 0.1429 0.7143 0.8571 0.4286
5 0.0000 0.0000 1.0000 1.0000 1.0000 0.0000 0.0000 1.0000 0.0000 1.0000 1.0000 1.0000
6 0.9158 0.9303 0.9459 0.9429 0.9386 0.9529 0.9590 0.9509 0.9706 0.9912 0.9952 1.0000
7 1.0000 1.0000 0.5000 0.5000 0.5000 0.5000 1.0000 0.5000 1.0000 0.0000 0.0000 0.0000
8 0.8571 0.5714 0.7143 0.8571 0.4286 1.0000 0.7143 1.0000 1.0000 0.0000 0.0000 0.0000
9 1.0000 1.0000 0.0000 0.0000 1.0000 1.0000 1.0000 0.0000 1.0000 0.0000 0.0000 0.0000]
10
```

*Matriz de entradas para la validación del producto DF  
Matriz de 9x12*

```
C:\MATLAB6p5\work\Target_Val_DONAFAN.m
File Edit Text Window Help
Target_Val_DF = [0.4681 0.3932 0.6120 0.5734 0.5658 0.4378 0.4089 0.6171 0.3265 0.6573 0.6805 0.8332]
1
2
```

*Matriz de salidas para la validación del producto DF  
Matriz de 1x12*

- **Archivos .M del producto RG**

Los siguientes archivos contienen las matrices que serán utilizadas en el Neural Network para el entrenamiento y validación de la Red Neuronal que pronostique la cantidad demandada del producto RG.

```

C:\Documents and Settings\Administrador\Escritorio\eybi-tesis\Entradas_Ent_RG.m
File Edit Text Window Help
1 Entradas_Ent_RG=[0.0833 0.1667 0.2500 0.3333 0.4167 0.5000 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000 0.0833 0.1667 0.2500 0.3333 0.4167 0
2 0.5658 0.6184 0.5670 0.5918 0.6636 0.6524 0.6085 0.6005 0.6079 0.5943 0.6017 0.5936 0.6116 0.6196 0.6184 0.6104 0.6729 0.7075 0
3 0.0000 0.0000 0.5000 1.0000 0.0000 1.0000 1.0000 0.5000 0.0000 0.0000 0.5000 0.0000 0.5000 0.0000 0.5000 0.0000 0.5000 1.0000 0
4 0.0000 0.0000 0.2857 0.7143 0.0000 0.4286 0.5714 0.4286 0.0000 0.0000 0.5714 0.0000 0.5714 0.0000 1.0000 0.0000 1.0000 0.2857 0
5 1.0000 1.0000 1.0000 1.0000 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000 1.0000 1.0000 1.0000 0.0000 1.0000 1.0000 0.0000 0.0000 1
6 0.7422 0.6720 0.7093 0.6889 0.7156 0.7218 0.7093 0.7316 0.6524 0.6524 0.6427 0.6818 0.7067 0.6827 0.7102 0.7173 0.7342 0.7253 0
7 0.0000 0.0000 0.3333 0.3333 0.3333 0.3333 0.0000 0.3333 0.0000 0.3333 0.6667 0.0000 0.0000 0.6667 0.3333 0.0000 0.0000 0.6667 0
8 0.0000 0.0000 0.1667 0.3333 0.1667 0.6667 0.0000 0.5000 0.0000 0.6667 0.8333 0.0000 0.0000 0.5000 0.3333 0.0000 0.0000 0.1667 0
9 1.0000 1.0000 0.0000 0.0000 1.0000 0.0000 1.0000 1.0000 1.0000 0.0000 1.0000 1.0000 0.0000 1.0000 1.0000 1.0000 1.0000 1.0000 1
10
11

```

*Matriz de entradas para el entrenamiento del producto RG  
Matriz de 9x45*

```

C:\Documents and Settings\Administrador\Escritorio\Target_Ent_RG.m
File Edit Text Window Help
1 Target_Ent = [
2 0.6892 0.5971 0.5963 1.0000 0.5503 0.5837 0.3243 0.6186 0.5256 0.5337 0.6384 0.5986 0.6689 0.8397 0.4776 0.5999 0.6078 0.6799 0.391
3

```

*Matriz de salidas(targets) para el entrenamiento del producto RG  
Matriz de 1x 45*

```

C:\Documents and Settings\Administrador\Escritorio\Entradas_Val_RG.m
File Edit Text Window Help
1 Entradas_Val = [
2 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000
3 0.9839 0.9823 0.9758 0.9775 0.9855 0.9855
4 1.0000 0.5000 0.0000 0.5000 0.5000 0.5000
5 0.2857 0.2857 0.0000 0.2857 0.4286 0.2857
6 0.0000 0.0000 0.0000 1.0000 0.0000 0.0000
7 0.8993 0.9011 0.9267 0.8223 0.9103 0.9139
8 0.0000 0.5000 0.0000 0.5000 0.0000 0.0000
9 0.0000 0.2857 0.0000 0.5714 0.0000 0.0000
10 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000]
11

```

*Matriz de entradas para la validación del producto RG  
Matriz de 9x6*

```

C:\Documents and Settings\Administrador\Escritorio\eybi-tesis\Target_Val_RG.m
File Edit Text Window Help
1 Target_Val_RG = [0.5554 0.5863 0.3495 0.4603 0.4071 0.3393]
2

```

*Matriz de salidas para la validación del producto RG  
Matriz de 1x6*

- **Archivos .M del producto CH**

Los siguientes archivos contienen las matrices que serán utilizadas en el Neural Network para el entrenamiento y validación de la Red Neuronal que pronostique la cantidad demandada del producto CH.

```

C:\Documents and Settings\Administrador\Escritorio\Entradas_Ent_CHARCOT.m
File Edit Text Window Help
Entradas_Ent = [
1 0.0833 0.1667 0.2500 0.3333 0.4167 0.5000 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000 0.0833 0.1667 0.2500 0.3333 0.4167 0.5000 0.5833 0.66
2 0.8502 0.8438 0.8309 0.8325 0.8277 0.9565 0.8776 0.8261 0.8422 0.9871 0.8277 0.8390 0.8438 0.8454 0.8792 0.8647 0.8760 0.9050 0.9404 0.94
3 1.0000 0.5000 0.5000 1.0000 0.5000 0.0000 0.0000 0.5000 0.5000 0.0000 0.5000 0.5000 0.5000 1.0000 0.5000 0.0000 0.0000 0.5000 0.0000 1.00
4 0.5714 0.1429 0.1429 1.0000 0.1429 0.0000 0.0000 0.2857 0.1429 0.0000 0.2857 0.4286 0.5714 0.7143 0.2857 0.0000 0.0000 0.4286 0.0000 0.42
5 1.0000 1.0000 0.0000 1.0000 0.0000 1.0000 0.0000 1.0000 0.0000 1.0000 0.0000 0.0000 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000 0.0000 1.00
6 0.8260 0.8114 0.8590 0.9011 0.9194 0.9579 0.9359 0.8571 0.8846 0.9487 0.8956 0.9396 0.9432 0.9066 0.9176 0.8407 0.8590 0.8919 0.8993 0.91
7 0.0000 0.0000 0.5000 0.0000 0.5000 0.0000 0.5000 0.5000 0.5000 1.0000 0.0000 0.0000 0.5000 0.0000 0.0000 0.0000 0.0000 0.0000 0.0000 0.00
8 0.0000 0.0000 0.1429 0.0000 0.1429 0.0000 0.8571 0.2857 0.1429 0.5714 0.1429 0.0000 0.0000 0.2857 0.0000 0.0000 0.0000 0.0000 0.0000 0.00
9 1.0000 1.0000 0.0000 1.0000 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000 1.0000 1.0000 0.0000 1.0000 0.0000 1.0000 0.0000 1.0000 1.0000 1.00
10
11

```

*Matriz de entradas para el entrenamiento del producto CH  
Matriz de 9x30*

```

C:\Documents and Settings\Administrador\Escritorio\Target_Ent_CHARCOT.m
File Edit Text Window Help
Target_Ent = [
1 0.6892 0.5971 0.5963 1.0000 0.5503 0.5837 0.3243 0.6186 0.5256 0.5337 0.6384 0.5986 0.6689 0.8397 0.4776 0.5999 0.6078 0.6799 0.3910 0.73
2
3

```

*Matriz de salidas(targets) para el entrenamiento del producto CH  
Matriz de 1x 30*

```

C:\Documents and Settings\Administrador\Escritorio\Entradas_Val_CHARCOT.m
File Edit Text Window Help
Entradas_Val = [
1 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000
2 0.9839 0.9823 0.9758 0.9775 0.9855 0.9855
3 1.0000 0.5000 0.0000 0.5000 0.5000 0.5000
4 0.2857 0.2857 0.0000 0.2857 0.4286 0.2857
5 0.0000 0.0000 0.0000 1.0000 0.0000 0.0000
6 0.8993 0.9011 0.9267 0.8223 0.9103 0.9139
7 0.0000 0.5000 0.0000 0.5000 0.0000 0.0000
8 0.0000 0.2857 0.0000 0.5714 0.0000 0.0000
9 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000]
10
11

```

*Matriz de entradas para la validación del producto CH  
Matriz de 9x6*

```

C:\Documents and Settings\Administrador\Escritorio\Target_Val_CHARCOT.m
File Edit Text Window Help
Entradas_Val = [
1 0.6480 0.6161 0.6770 0.5635 0.6980 0.6671]
2
3

```

*Matriz de entradas para la validación del producto CH  
Matriz de 1x6*

# *Anexo E*

## *Selección de las variables de entrada*

## Variables para pronósticar la demanda de productos farmacéuticos

### Entrevista

#### 1. Datos Personales

Datos de Experto
<b>Nombre:</b> Carlos López Martínez (Denominación)
<b>Área:</b> Marketing
<b>Objetivo:</b> Obtener las variables actuales con las que cuenta el experto para poder hallar la cantidad de demanda de productos farmacéuticos OTC y poder añadir otras variables que se consideran necesarias según su experiencia.
<b>Descripción:</b> Se mencionarán variables teóricas que han sido comprobadas mediante estudios técnicos, que influyen directamente en el pronóstico de productos generales y otras variables que se deben seleccionar igualmente puesto que son influyentes en el proceso de pronóstico de productos farmacéuticos que son consideradas aptas para tomarse en cuenta.
<b>Fecha:</b> 15/01/2009

2. Según los estudios realizados se llegó a la conclusión que existe variables que son determinantes para el pronóstico de un producto o servicio, las cuales son consideradas para el pronóstico de productos farmacéuticos, a continuación los detalles.

Variables	Observación
Precio del Producto <input checked="" type="checkbox"/>	
Ingreso del Consumidor <input type="checkbox"/>	Por ser productos farmacéuticos OTC el ingreso del consumidor no influye en gran medida en la desviación de la demanda.
Gustos y Preferencias <input type="checkbox"/>	Los gustos y preferencias de los consumidores no es una variable ya que para comprar un producto farmacéutico no depende si el usuario gusta del medicamento o no.
Precio del bien sustituto <input checked="" type="checkbox"/>	
Precio del bien complementario <input type="checkbox"/>	Los productos que se venden no requieren de otro producto para su venta.

3. Indicar variables que considera actualmente para pronósticar la demanda y agregue variables que influyen en la demanda y actualmente no las consideran.

Variables Consideradas	Observación
Publicidad de productos <input checked="" type="checkbox"/>	La publicidad del producto es muy determinante para la venta, se transmite por algún medio o por referencias de especialista e incluso de persona que lo han

	<input type="checkbox"/>	consumido.
Publicidad del bien sustituto	<input checked="" type="checkbox"/>	La publicidad del bien sustituto influye en la demanda de nuestro producto ya que cuando hay mas publicidad del producto competente nuestras ventas disminuyen
Publicidad del bien complementario	<input type="checkbox"/>	
Periodo de pronóstico	<input checked="" type="checkbox"/>	En nuestro caso, la compra de productos farmacéuticos es una vez al mes, y a la vez muchos de ellos dependen de la estación, por tanto el mes es importantes.
Intensidad de la publicidad	<input type="checkbox"/>	

Variables a considerar		Observación
Existencia de la promoción del producto	<input checked="" type="checkbox"/>	Se toma en cuenta en la empresa para predecir el siguiente stock.
Tiempo de la promoción	<input checked="" type="checkbox"/>	También se toma en cuenta
Existencia de la promoción del bien sustituto	<input checked="" type="checkbox"/>	Tenemos en cuenta a la competencia, porque su promoción puede influir en nuestra venta.
Tiempo de la promoción del bien sustituto	<input checked="" type="checkbox"/>	La misma explicación
	<input type="checkbox"/>	

#### 4. Observaciones Generales

El pronóstico de productos farmacéuticos OTC es muy volátil, ya que son productos que se pueden vender sin receta médica por lo tanto es muy difícil predecir en la mayoría de los casos.

Si se está pensando realizar un sistema inteligente que ayude en este proceso, pues sería impresionante ya que nos ayudaría a acercarnos a datos más exactos, a pronósticos más precisos y nos evitaria realizar el trabajo del análisis previo.