

**DISEÑO DE UN SISTEMA DE PRONOSTICO DE LA DEMANDA DE
NITROGENO Y OXIGENO PARA LA COMPAÑÍA CRYOGAS, S.A. BASADO EN
REDES NEURONALES.**

DANIEL MAURICIO ROSAS PABÓN

**UNIVERSIDAD EAFIT
ESCUELA DE INGENIERIA**

2014

**DISEÑO DE UN SISTEMA DE PRONOSTICO DE LA DEMANDA DE
NITROGENO Y OXIGENO PARA LA COMPAÑÍA CRYOGAS, S.A. BASADO EN
REDES NEURONALES.**

DANIEL MAURICIO ROSAS PABÓN

Trabajo de grado presentado para optar al título de Maestría en Ingeniería

Asesor: SERGIO AUGUSTO RAMIREZ ECHEVERRI

**UNIVERSIDAD EAFIT
ESCUELA DE INGENIERIA**

2014

Nota de aceptación

Presidente del jurado

Jurado

Jurado

Jurado

Medellín, mayo de 2014.

DEDICATORIA

A mi familia, por su comprensión, apoyo e inspiración que me han permitido mi desarrollo profesional.

AGRADECIMIENTOS

Al profesor Sergio Augusto Ramírez por su gran apoyo, dedicación e interés por llevar a cabo esta investigación.

Contenido

?

Lista de figuras.....	9?
Lista de tablas.....	11?
GLOSARIO	13?
RESUMEN.....	15?
Introducción.	16?
1. Antecedentes.	17?
1.1 Planteamiento del problema.....	17?
1.1.1 Definición del problema.....	17?
1.1.2 Delimitación del problema.....	27?
1.2 JUSTIFICACION.....	28?
1.3 OBJETIVOS DEL PROYECTO.....	28?
1.3.1 Objetivo general.....	28?
1.3.2 Objetivos específicos.....	28
2. Estado del Arte.	30?
2.1 Demanda.....	31?
2.2 Pronostico	31?
2.3 Regla de Peterson-Silver.....	31?
2.4 Redes neuronales	33?
2.4.1 Definición.....	33?
2.4.2 Elementos básicos de las Redes Neuronales	33?
2.4.3 Arquitecturas de las Redes Neuronales Artificiales.....	36?

2.4.4 Clasificación de las redes neuronales artificiales.	37
2.5. Métodos de pronóstico	39
2.5.1 Métodos cuantitativos.....	39
2.5.2 Métodos cualitativos	40
2.5.3 Redes neuronales	41
2.5.3.1 Perceptrón Multicapa.....	41
2.5.3.2 Red Elman – Jordan.....	42
2.5.3.3 Redes de base radial.....	42
2.6 Casos de estudio.....	44
2.6.1 Predicción de la demanda eléctrica horaria mediante RNA	44
2.6.2 Aplicación de RNA en el análisis de datos: comparación entre RNA y modelos estadísticos clásicos.	48
2.6.3 Demanda energética a mediano plazo pronosticada a través de modelos Neuro Fuzzy.....	50
2.6.4 Evaluación comparativa entre métodos de pronóstico.	55
2.6.5 Evaluación comparativa entre diferentes arquitecturas de redes neuronales para el pronóstico.....	62
2.6.5.1 Criterios para la comparación de redes neuronales.	62
2.7 Software para pronosticar basados en redes neuronales artificiales.	67
2.7.1 Neuro Shell. http://www.neuroshell.com/	67
2.7.2 Neural Network Forecasting Software by BI3S lab. http://www.bis-lab.com/neural-network-software.htm	67
2.7.3 GMDH Shell www.gmdhshell.com/neural-network-software	68
2.7.4 Alyuda Forecaster XL http://www.alayuda.com/forecasting-excel-software-with-neural-network.htm	68

2.7.5 Neural Tools for Excel Palisade. http://www.palisade-Ita.com/neuraltools/68	
2.7.6 Matlab® www.matlab.com	69
3. Diseño de la RNA para el pronóstico de Oxígeno líquido medicinal y nitrógeno líquido para uso del sector petrolero.....	70
3.1 Descripción grafica del procedimiento para la generación del pronóstico....	70
3.1.1 Identificación de variables de entrada a la RNA.....	71
3.1.2 Recopilación de datos históricos de ventas y entradas de la RNA.....	71
3.1.3 Construcción red neuronal artificial.	74
3.1.3.1 Definición de entradas y salidas.....	74
3.1.4 Construcción de la RNA.....	74
3.1.5. Tratamiento de los datos para las entradas de la red	76
3.1.6 Entrenamiento de la RNA y validación de resultados.....	77
4. CONCLUSIONES	87
Bibliografía.....	89
ANEXOS	91

Lista de figuras

Figura 1 Diagrama de bloques planta ASU (Claveria, Lozano, & Hombrados, 2001)	18
Figura 2. Planta ASU Barbosa (Antioquia)	20
Figura 3. Eficiencia planta Sibaté Junio 2012 – Junio 2013. Fuente propia	21
Figura 4. Eficiencia planta Barbosa Junio 2012 – Junio 2013. Fuente propia	22
Figura 5. Paradas planta Sibaté Junio 2012 – Junio 2013	22
Figura 6. Paradas planta Barbosa junio 2012 – Junio 2013	23
Figura 7. Volumen de oxígeno medicinal mes a mes, comparativo año a año	24
Figura 8. Volumen histórico oxígeno medicinal	25
Figura 9. Volumen de nitrógeno exploración petrolera mes a mes, comparativo año a año	26
Figura 10. Volumen histórico nitrógeno exploración petrolera	27
Figura 11 Modelo genérico de una red neuronal artificial. (Martín & Sanz, 1997)	34
Figura 12 Interconexión entre una neurona presináptica y una postsináptica. (Martín & Sanz, 1997)	35
Figura 13 Funciones de activación habituales. (Martín & Sanz, 1997)	36
Figura 14 Capas de una red neuronal artificial. (Martín & Sanz, 1997)	37
Figura 15 Clasificación de las redes neuronales artificiales por el tipo de aprendizaje y arquitectura. (Martín & Sanz, 1997)	39
Figura 16 Perceptrón Multicapa. (Martín & Sanz, 1997)	42
Figura 17 Redes de arquitectura Elman y Jordan. (http://www.disa.bi.ehu.es/spanish/profesores-etsi-bilbo/~jtjpcaxi/PFC/wwwANN/arquitectura_archivos/image012.gif , 2013)	42
Figura 18 Red Radial. (http://softwarelibre.unsa.edu.ar/docs/descarga/2003/curso/htmls/redes_neuronales/x185.html , 2003)	43

Figura 19 Arquitectura de la RED	44
Figura 20 Respuesta de la RNA entrenada frente a la muestra inicial.....	46
Figura 21 Respuesta de la RNA entrenada frente a datos desconocidos.....	47
Figura 22 Estructura Sistema Neuro-Fuzzy	51
Figura 23 Demanda Gasolina vs pronóstico de la demanda de Gasolina.	52
Figura 24 Demanda petróleo vs pronóstico demanda petróleo año 2009.....	53
Figura 25 Demanda gas natural vs pronóstico demanda Gas natural 2008	54
Figura 26. Flujo para la generación de pronóstico con RNA.....	70
Figura 27 Arquitectura RNA para la LOMX y LINP. Fuente propia.	75
Figura 28 Respuesta de la RNA vs datos originales.....	79
Figura 29 Validación de datos, dato pronosticado vs dato real pronosticador 1. ...	79
Figura 30 Validación de datos, dato pronosticado vs dato real pronosticador 2. ...	80
Figura 31 Validación de datos, dato pronosticado vs dato real pronosticador 3. ...	80
Figura 32 Validación de datos, dato pronosticado vs dato real pronosticador 4. ...	81
Figura 33 Validación de datos, dato pronosticado vs dato real pronosticador 1. ...	84
Figura 34 Validación de datos, dato pronosticado vs dato real pronosticador 2. ...	84
Figura 35 Validación de datos, dato pronosticado vs dato real pronosticador 3. ...	85
Figura 36 Validación de datos, dato pronosticado vs dato real pronosticador 4. ...	85

Lista de tablas

Tabla 1. Clasificación del volumen del oxígeno líquido por aplicación.....	23
Tabla 2. Volúmenes históricos oxígeno medicinal.	24
Tabla 3. Clasificación del volumen del oxígeno líquido por aplicación.....	25
Tabla 4. Volúmenes históricos Nitrógeno exploración petrolera.	26
Tabla 5 Variables de entrada para la predicción de demanda eléctrica.....	45
Tabla 6 Valores óptimos para el entrenamiento de la RNA.	46
Tabla 7 Resultados de la comparación entre modelos de pronóstico.....	48
Tabla 8 Equivalencia en terminología estadística y redes neuronales. (Moreno, 2002).....	49
Tabla 9 Equivalencia de modelos estadísticos y modelos de red neuronal.	50
Tabla 10 Variables de entrada para el pronóstico de la demanda energética.	52
Tabla 11 Comparación demanda vs pronóstico de la gasolina.....	53
Tabla 12 Comparación demanda vs pronóstico del petróleo.	54
Tabla 13 Comparación demanda vs pronóstico del Gas natural.....	55
Tabla 14 Parámetros de evaluación y comparación de métodos de pronóstico. ...	59
Tabla 15 Comparación de métodos criterio a criterio cualitativamente.....	60
Tabla 16 Comparación de métodos criterio a criterio cuantitativamente.....	61
Tabla 17 Parámetros de evaluación y comparación de redes neuronales.....	65
Tabla 18 Comparación de RNA criterio a criterio cuantitativamente.....	66
Tabla 19 Comparación de RNA criterio a criterio cuantitativamente.....	66
Tabla 20. Datos históricos de volúmenes de ventas oxígeno líquido medicinal	72
Tabla 21. Datos históricos de volúmenes de ventas nitrógeno explotación petrolera	73
Tabla 22 Tabla comparativa pronosticadores de LINP.	78
Tabla 23 Resumen pronósticos LINP	81
Tabla 24 Comparativo pronósticos RNA vs Pronostico Cryogas y volúmenes reales.....	82

Tabla 25 Tabla comparativa pronosticadores de LOXM.....	83
Tabla 26 Resumen pronósticos LOXM.....	86
Tabla 27 Comparativo pronósticos RNA vs Pronostico Cryogas y volúmenes reales.....	86
Tabla 28 Comparación método actual y propuesto LOXM.....	87
Tabla 29 Comparación método actual y propuesto LIMP.....	88

LISTA DE ANEXOS

ANEXO A: Variables entradas RNA LOXM	91
ANEXO B: Variables entradas RNA LINP	94
ANEXO C: Datos entradas RNA LOXM originales.....	97
ANEXO D: Datos entradas RNA LINP originales.....	99
ANEXO E: Entradas RNA LOXM datos normalizados	101
ANEXO F: Entradas RNA LINP datos normalizados	104

GLOSARIO

Eficiencia energética planta ASU: Este indicador es usado en las plantas ASU para determinar el consumo de electricidad por unidad terminada producida, Cryogas hace uso de este indicador como parámetro de eficiencia y costo de producto.

LAR: Argón en estado líquido con una pureza de 99.9998% y a una temperatura de -186 °C.

LIN: Nitrógeno en estado líquido con una pureza de 99.9998% y a una temperatura de -196°C.

LINP: Nitrógeno en estado líquido usado en el sector petrolero.

LOX: Oxígeno en estado líquido con una pureza de 99.9998% y a una temperatura de -183°C.

LOXM: Oxígeno en estado líquido usado en el sector medicinal

Planta ASU: Planta de separación de aire mediante destilación fraccionada. Se obtienen los componentes principales del aire separados en estado líquido.

RNA: Red neuronal artificial

RESUMEN

La dinámica del mercado en los últimos años ha llevado a Cryogas a optimizar sus costos de producción y evitar agotados, maximizando el servicio al cliente y la rentabilidad de sus productos,

La realización este proyecto es con el objetivo de identificar la metodología propuesta genera un pronóstico acertado frente a los métodos y resultados utilizados actualmente y mejorar los costos productivos mediante una producción con una mejor eficiencia energética.

La investigación parte de la identificación de variables que afecta la demanda de los productos con mayor irregularidad, para cuantificar y generar entradas para los diferentes modelos de redes neuronales. Se realizaron varios pronósticos con diferentes modelos cuyos resultados se comparan con datos de control para seleccionar el de mejor desempeño y mayor exactitud. Los resultados obtenidos con el modelo de pronóstico de mejor desempeño se comparan con realidad y el método usado actualmente por Cryogas para identificar el mejor.

Los resultados obtenidos permiten una mejora en los procedimientos de Cryogas que impactaran positivamente la rentabilidad de la compañía, se tendrán parámetros de generación de pronósticos basados en criterios sólidos y se buscara eliminar la subjetividad en esta actividad.

Palabras Claves: REDES NEURONALES ARTIFICIALES, PRONOSTICOS, EFICIENCIA, SERVICIO, DEMANDA.

Introducción.

Los pronósticos de las ventas de los diferentes productos son una información fundamental para la toma de decisiones en el departamento comercial, producción, logística, finanzas y recursos humanos.

La desacertada predicción puede generar un muy alto inventario, gastos innecesarios del departamento comercial, reducciones de precio, pérdida de ventas, programas ineficientes de producción y planeación inexacta del flujo de caja e inversión de capital tanto de trabajo como para crecimiento de la compañía.

Un cambio permanente de las tendencias del mercado, el arribo de nuevos jugadores internacionales a Colombia y los complejos momentos de la economía hacen que las compañías deban ser más productivas y tener los métodos necesarios para poder tomar las acciones correctas y a tiempo sin afectar a los clientes y aumentar la rentabilidad de la Compañía.

Esta tesis de maestría tiene como objetivo identificar los principales aspectos que intervienen en los cambios en la demanda de los 2 productos más importantes de la empresa y que impactan fuertemente los resultados de Cryogas, S.A.

El proyecto busca generar una metodología que permita el uso del modelo más adecuado de pronóstico de la demanda. Los modelos de pronóstico es una parte fundamental en la toma de decisiones de la compañía.

1. Antecedentes.

1.1 Planteamiento del problema.

Se plantea una situación real de la compañía Cryogas la cual es susceptible a mejoramiento. Para dar solución se exploran diferentes alternativas a través de investigación académica y aplicación práctica de conceptos.

1.1.1 Definición del problema.

CRYOGAS en Colombia fundada hace 65 años, actualmente perteneciente al grupo *Air Products®*, es una empresa productora y comercializadora de gases del aire (oxígeno, nitrógeno y argón), que además ofrece un amplio portafolio en gases industriales, mezclas, gases medicinales y científicos, productos y equipos para soldadura, además de productos complementarios como discos abrasivos, elementos de seguridad para el soldador y completos servicios de asistencia técnica y soporte comercial en todo el país.

Actualmente los criterios para la producción, almacenamiento e importación de los productos no son realizados bajo un análisis estructurado y sistémico que permita cuantificar las variables externas que afectan el proceso comercial y mucho menos tomar medidas para mitigar su impacto en la compañía.

Cryogas para atender a sus clientes actuales y proyectando expansión y crecimiento a futuro cuenta con 2 plantas ASU (*Air Separation Unit*) ubicadas en Sibaté (Cundinamarca) y en Barbosa (Antioquia), productoras de Nitrógeno, Oxígeno y Argón a partir de la destilación de moléculas en el aire. La producción parte de la misma composición del aire que es un 78% Nitrógeno, 21% Oxígeno, un 0.9% Argón y un 0.1% de otros gases, gases que para poder separarlos se hace uso del proceso de destilación fraccionada, proceso que lleva a la mezcla gaseosa a ser licuada mediante la disminución de temperatura y el aumento de presión.

Todos los procesos criogénicos están basados en la compresión del aire y su posterior enfriamiento a temperaturas muy bajas, para conseguir su licuefacción parcial. Esto permite su destilación criogénica (basada en el fenómeno donde cada uno de los componentes puros del aire se licúa a temperaturas diferentes) para separar los productos en una columna de múltiples etapas. Puesto que la temperatura del proceso es muy baja es necesario que equipos como la columna de destilación, intercambiadores de calor y otros componentes estén aislados

frente a transferencia de calor desde el medio ambiente. En la práctica estos componentes se ubican en cajas frías.

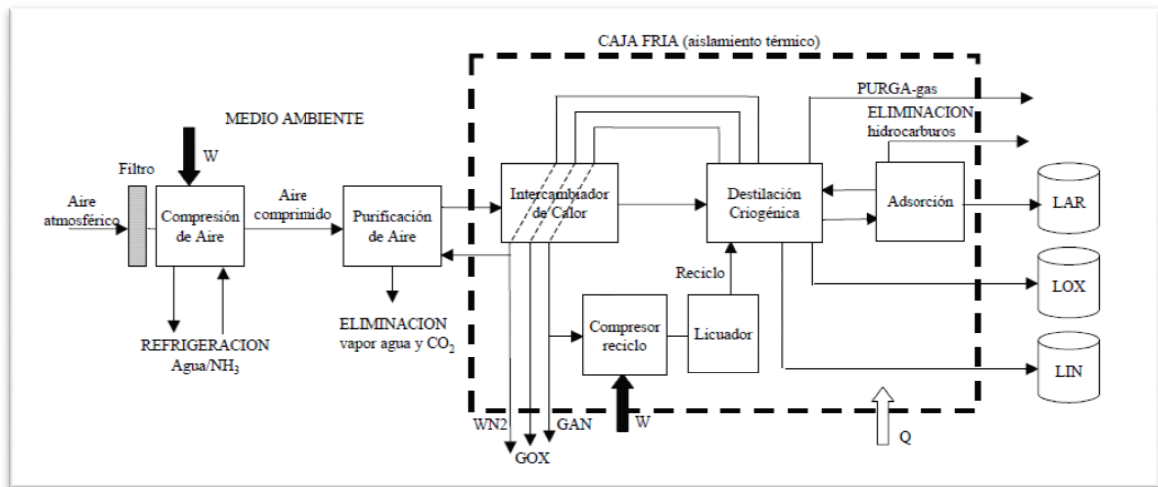


Figura 1 Diagrama de bloques planta ASU (Claveria, Lozano, & Hombrados, 2001)

La separación criogénica del aire conlleva los siguientes procesos principales, inicialmente el aire de alimentación a la planta es filtrado y comprimido (aproximadamente a 87 *psi*). A continuación el aire se seca mediante su enfriamiento en un intercambiador aire-agua o aire-aire y con el posible apoyo de un sistema de refrigeración mecánica. La eliminación total del vapor de agua, anhídrido carbónico y otros contaminantes (hidrocarburos) se realiza mediante tamices moleculares que tienen ciclos de trabajo de 8 horas cada uno, así mientras un tamiz se está regenerando el otro se encuentra filtrando el aire que ingresa al sistema. El enfriamiento del aire a temperaturas criogénicas se lleva a cabo en intercambiadores de calor multiflujo que aprovechan la capacidad de refrigeración de los gases que salen de la planta.

Las columnas de destilación separan el aire en los productos deseados. Las plantas de nitrógeno pueden tener una sola columna; sin embargo las plantas para producir oxígeno deben tener dos columnas, de alta y baja presión, de tal manera que el oxígeno impuro de la columna de alta presión es purificado en la columna de baja presión. Las plantas para producir oxígeno de alta pureza tienen una columna adicional diseñada para separar el argón del oxígeno, estas son las planta ASU que posee Cryogas. El producto de esta columna de argón crudo (Argón con presencia de 2% de oxígeno) puede ser purificado en una columna de argón puro eliminando el oxígeno y nitrógeno residual. El sistema de argón puro puede utilizar una unidad de adsorción que combinando oxígeno con hidrógeno forma agua fácilmente eliminable.

Los productos gaseosos fríos (y los flujos residuales) son introducidos en el intercambiador principal de la planta en contracorriente con el aire caliente de alimentación, de tal forma que este es enfriado y los otros calentados a una

temperatura próxima a la ambiental. Este intercambio entre la alimentación y los productos minimiza las necesidades netas de refrigeración de la planta.

Para compensar las entradas de calor desde el medio ambiente y proporcionar el gradiente de temperatura necesario entre los flujos que intercambian calor es necesario proporcionar una refrigeración extra a la planta. Para lograrlo, a uno o más flujos gaseosos a alta presión (aire de alimentación, gas residual o gases producidos) se les hace pasar a través de una turbina con lo que se consigue el enfriamiento del gas.

Las plantas de Cryogas una vez terminan el proceso de destilación obtienen los siguientes productos con estas características:

Oxígeno líquido (O₂) = (-183 °C)

Argón líquido (Ar) = (-186 °C)

Nitrógeno líquido (N₂) = (-196°C)

Y una producción cuyos máximos y mínimos son los siguientes:

LOX (Oxígeno líquido), entre 56 y 70 TON/día.

LIN (Nitrógeno líquido), entre 23 y 44 TON/día.

LAR (Argón líquido), entre 2.4 y 3.3 TON/día.

La producción total es una combinación de las posibilidades anteriormente nombradas que sumadas en su totalidad generan un total de 110 TON/día.

Todo el producto es almacenado en tanques criogénicos de baja presión que tienen las siguientes características:

- Oxígeno líquido 55.000 galones. Equivalentes a 350 TON de producto terminado.
- Nitrógeno líquido 55.000 galones. Equivalentes a 250 TON de producto terminado
- Argón líquido 6.000 galones. Equivalentes a 30 TON de producto terminado.

Por la densidad propia de cada elemento el almacenamiento másico de cada producto terminado varia aun estando en tanque de la misma capacidad volumétrica.

Las plantas ASU para lograr la flexibilidad en la producción deben regular la cantidad de aire que se toma de la atmosfera y combinar la producción de

oxígeno, nitrógeno y argón, aumentando uno y disminuyendo los otros, igualmente de debe hacer uso de compresores auxiliares según sea la configuración de la producción. El tiempo para un cambio de *set up* es de 24 horas aproximadamente, el consumo energético continúa constante pero la producción se reduce en un 30%, aumentando el costo del producto final, por esto es muy importante un buen pronóstico de la demanda.

Un parámetro adicional a tener en cuenta es que los tanques de almacenamiento son fijos, no se pueden ampliar, cambiar de servicio o mezclar producto terminado en su interior, lo que presenta un limitante. Las plantas ASU no pueden independizar la producción de ningún producto, se debe producir de manera simultánea Oxígeno, Nitrógeno y Argón, son dependientes el uno del otro por el proceso mismo de la destilación, al no tener un correcto equilibrio entre la producción y la demanda se presenta un desbalance entre producción y almacenamiento. Cuando la planta para con almacenamiento no uniforme en los diferentes productos obliga a arrancar la planta nuevamente a los 2 o 3 días por la necesidad de los otros productos que no se tienen en cantidad suficiente, cada arranque de planta dura entre 14 y 16 horas, consume un 20% más de energía eléctrica y su producción en 24 horas es un 80% menor que cuando está estable, esta operación se debe realizar la menor cantidad de veces posibles.



Figura 2. Planta ASU Barbosa (Antioquia).

En el momento que uno de los tanques de almacenamiento de cualquier producto este lleno se debe parar la planta, de lo contrario la producción excedente deberá ser desechada a la atmosfera. Si se presentara esta situación se genera un aumento en el costo del producto que continua en producción y con espacio para almacenamiento (el costo del producto desechado hará parte del costo del producto), impactando directamente la rentabilidad de la compañía.

Para medir y poder controlar los costos unitarios de producción se contempla como parámetro de medición la eficiencia energética que es la relación de los KWs empleados para la producción de todos los productos es un lapso de tiempo. Se hace un control diario y se consolida de manera mensual.

$$\frac{\text{Costo Total}}{\text{Producción Total}} = \text{Costo Unitario}$$

La eficiencia es afectada por una continua variaciones de la demanda, se busca obtener la menor relación del indicador debido a que a menor factor menor costo unitario de producto final.




Figura 3. Eficiencia planta Sibaté Junio 2012 – Junio 2013. Fuente propia.




Figura 4. Eficiencia planta Barbosa Junio 2012 – Junio 2013. Fuente propia.

La eficiencia se ha visto afectada igualmente por las paradas no planeadas y mucho más con el aumento en la frecuencia de dichas paradas.




Figura 5. Paradas planta Sibaté Junio 2012 – Junio 2013.




Figura 6. Paradas planta Barbosa junio 2012 – Junio 2013.

Se observa que la planta ASU Sibaté, el indicador de eficiencia va aumentando al igual que el número de paradas al mes, generando un mayor costo unitario del producto final y una disminución en la rentabilidad de la compañía. Planta Barbosa a pesar de ser más estable presenta también una leve tendencia al aumento en el indicador de la eficiencia.

Las principales aplicaciones y comportamientos de los productos que comercializa Cryogas son las siguientes Oxígeno, Nitrógeno y Argón:

Las principales aplicaciones del Oxígeno son:

Clasificación del volumen del oxígeno líquido por aplicación	
Industria	Industria
Industria	Industria
Industria	Industria
Industria	Industria
Industria	Industria

Tabla 1. Clasificación del volumen del oxígeno líquido por aplicación.

Medicinal, en estado líquido (en tanques criogénicos) y gaseoso (cilindros) siendo usado en clínicas, hospitales y también en la parte domiciliaria por parte de pacientes con enfermedades respiratorias crónicas. La demanda de este sector **es inestable como se demuestra en el capítulo 2.3**. La demanda es afectada por el clima, orden público, la economía, la disponibilidad presupuestal en el sector público y crecimiento en el sector privado y otra serie de factores que se

profundizaran más adelante. Representa el 35% del volumen vendido por la compañía en este producto.

	ene	feb	mar	abr	may	jun	jul	ago	sep	oct	nov	dic
Volumenes 2009	656.333	611.721	685.570	664.910	651.619	723.777	682.554	692.506	702.973	683.327	692.322	733.223
Volumenes 2010	674.935	634.885	717.320	694.342	729.039	729.754	732.022	732.137	753.118	732.921	750.842	765.195
Volumenes 2011	689.641	668.373	761.403	748.129	833.327	777.940	755.150	775.695	752.817	687.854	765.518	833.928
Volumenes 2012	768.431	740.601	782.429	821.305	827.986	819.851	763.902	760.899	710.788	834.417	778.873	743.164
Volumenes 2013	781.373	658.200	748.351	903.076	827.857	759.713						

Tabla 2. Volúmenes históricos oxígeno medicinal.




Figura 7. Volumen de oxígeno medicinal mes a mes, comparativo año a año.




Figura 8. Volumen histórico oxígeno medicinal.

Industrial, principalmente en estado gaseoso, sus aplicaciones son en corte y soldadura. Este mercado es bastante estable y corresponde al 10% del volumen vendido por la compañía en este producto.

Procesos industriales, principalmente en estado líquido, donde las aplicaciones son en la industria metalúrgica, cerámica, química, del vidrio entre otras. Este mercado es muy estable, solo es impactado por factores externos puntuales de orden económico y el volumen corresponde al 55% vendido por la compañía en este producto.

Las principales aplicaciones de nitrógeno son:

Nitrógeno líquido	
Industria metalúrgica	20%
Industria química	15%
Industria del vidrio	10%
Industria cerámica	10%
Industria alimentaria	10%
Industria farmacéutica	10%
Industria electrónica	10%

Tabla 3. Clasificación del volumen del oxígeno líquido por aplicación.

Exploración Petrolera, aplicaciones en seguridad, pruebas y extracción de crudo, **demanda inestable como se demuestra en el capítulo 2.3**, afectada por orden público, demanda de crudo nacional e internacional, exploración de nuevos pozos, producción de Crudo, construcción de oleoductos y factores no fáciles de identificar y cuantificar, el volumen corresponde al 40% de lo vendido por la compañía en este producto.

	ene	feb	mar	abr	may	jun	jul	ago	sep	oct	nov	dic
Volumenes 2009	12.208	214.892	199.910	385.806	107.258	63.324	74.922	19.026	232.953	265.067	68.882	519.794
Volumenes 2010	88.484	39.595	56.700	60.254	78.655	64.254	70.257	35.279	28.289	55.512	89.991	30.771
Volumenes 2011	321.928	19.793	288.340	-	174.664	62.078	231.466	123.255	42.920	131.434	99.359	169.489
Volumenes 2012	257.025	89.089	102.026	145.165	350.796	183.546	48.734	64.511	210.361	10.706	67.650	260.720
Volumenes 2013	315.817	55.713	140.586	209.716	233.119	192.633						

Tabla 4. Volúmenes históricos Nitrógeno exploración petrolera.

Nota: en el mes de abril de 2011 no se presentaron ventas a este mercado.




Figura 9. Volumen de nitrógeno exploración petrolera mes a mes, comparativo año a año.




Figura 10. Volumen histórico nitrógeno exploración petrolera

Sector alimentos, aplicación en congelación, empaque de Snacks, con demanda estable, el volumen corresponde al 25% de lo vendido por la compañía en este producto.

Sector químico, aplicaciones en seguridad industrial, barrido de tuberías, anti explosiones, la demanda es estable y el volumen corresponde al 15% vendido por la compañía en este producto.

Refinerías, aplicaciones propias del sector, demanda muy estable, el volumen corresponde al 20% de lo vendido por la compañía en este producto.

Actualmente Cryogas tiene la oportunidad de **mejorar el pronóstico de ventas de estos productos**, y así tomar decisiones operativas en la medida que se van identificando las tendencias de consumo y no sobre la marcha como pasa en algunos casos en la actualidad, lo que puede generar un desbalanceo de las plantas en su almacenamiento o agotados.

1.1.2 Delimitación del problema.

El proyecto se realizara en la compañía Cryogas en la oficina principal, y cubrirá la producción de las plantas de Sibaté (Cundinamarca) y Barbosa (Antioquia), se aplicara al Oxígeno líquido medicinal, Nitrógeno líquido para el Mercado del sector petrolero.

No se incluirá ninguna otra referencia ni producto en el desarrollo de este trabajo.

1.2 JUSTIFICACION.

Cryogas S.A. cuenta con herramientas tecnológicas y de la información para el control y gestión de su producción, manejo de inventarios e importaciones las cuales no se usando bajo parámetros técnicos que permita hacer un uso adecuado de la información, por lo tanto las decisiones operativas se toman basados en el criterio y la experticias de los participantes en diferentes puntos de la cadena de suministro generando costos que impactan negativamente la rentabilidad del negocio.

Se utiliza nuevos modelos y metodologías buscando mejorar los resultados y compararlos con los del día de hoy, si los resultados son mejores la metodología será aplicable.

La posibilidad de crear la metodología adecuada y probada con resultados confiables para el pronóstico de ventas en Cryogas se convierte en una oportunidad muy valiosa para lograr generar las herramientas necesarias para realizar análisis confiables de datos y la toma de decisiones operativas rentables y eficientes de cara al cliente y a la misma compañía.

1.3 OBJETIVOS DEL PROYECTO.

1.3.1 Objetivo general.

Diseñar e implementar un sistema de pronóstico de la demanda en Cryogas de los productos oxígeno líquido medicinal y nitrógeno líquido para el sector petrolero por medio de redes neuronales artificiales buscando obtener el menor error entre la demanda real y la demanda pronosticada.

1.3.2 Objetivos específicos.

- Analizar el proceso de ventas del oxígeno medicinal y el nitrógeno para exploración petrolera e identificar que variables pueden ser cuantificadas que intervengan en el proceso de demanda para su posterior uso en la generación de pronósticos.
- Analizar las diferentes técnicas para la generación de pronósticos de la demanda.
- Realizar la selección del método para pronosticar la demanda de los productos seleccionados.
- Proponer y construir la arquitectura más acorde con los productos a pronosticar, incluyendo el método de aprendizaje.

- Diseñar la metodología de predicción basada en herramientas tecnológicas y software usado actualmente.
- Evaluar los resultados obtenidos, comparar los resultados del método propuesto con los resultados obtenidos actualmente.
- Revisar el actual proceso de pronóstico de la demanda que posee Cryogas, analizar sus resultados.

2. Estado del Arte.

Toda industria y por lo general todas las actividades necesitan una planeación para que los objetivos esperados tengan el resultado deseado, incluso se puede concebir la planeación como una mirada al futuro antes que este suceda.

Una parte fundamental para llevar a cabo una buena planeación es tener un pronóstico que permita lograr mayor claridad el objetivo a alcanzar y las posibles tendencias, e igualmente anticiparnos a ciertos sucesos. Para realizar pronósticos se hace uso de métodos estadísticos convencionales que usan datos asociados a periodos de tiempo, cuyas relaciones con la previsión de la demanda no son tan claros, adicional que en la práctica los encargados de generar los pronósticos en las industrias hacen uso de su instinto y experticia para ajustar la demanda. Igualmente los pronósticos de la demanda deben satisfacer ciertos escenarios financieros por medio de cumplimiento de ventas o metas que inciden de manera subjetiva el horizonte de la demanda futura, cuando los elementos primordiales están relacionados con el mercado y los consumidores. Por lo general al interior de las empresas la planeación de la demanda tiene como principio un pronóstico por diferentes métodos ya sea estadístico o basado en el conocimiento de expertos en el área y muchas veces influenciado por diversos factores(GAITHER & FRAIZER, 2000), (Salazar & Cabrera-Ríos, 2007).

En un principio los pronósticos eran realizados por expertos que basaban sus predicciones en instinto y experticia adquiridos a lo largo del tiempo, en el pronóstico resultante por lo general se contempla un crecimiento contra el año anterior. Luego se pasa a hacer uso de modelos estadísticos convencionales y lineales como los modelos de regresión y análisis de series de tiempo, estos métodos demanda una buena cantidad de información histórica para poder generar los análisis necesarios, igualmente estos métodos buscan encontrar relaciones a lo largo del tiempo que difícilmente son fáciles y efectivas para determinar.

Por mucho tiempo el análisis de las tendencias de consumo en los pronósticos han sido dominados por estas técnicas estadísticas pero con la cada vez más frecuente presencia de relaciones no lineales (la mayoría de los procesos y eventos en la naturaleza son no lineales), limitan estos modelos, esto llevo a que se introdujera por primera vez en 1964 una RNA en el pronóstico de series de tiempo para el pronóstico del clima siendo su aplicación limitada en esta ocasión por falta de algoritmo de entrenamiento multicapa. Luego de esto y el desarrollo de algoritmos adecuados de entrenamiento de las RNA se ha intensificado su uso pronóstico de series de tiempo en un gran número de aéreas entre las cuales se encuentran las finanzas, generación de energía, medicina, recursos del agua y diversas ciencias ambientales.(Salazar & Cabrera-Ríos, 2007).

2.1 Demanda

Es una cantidad determinada de bienes o servicios que los consumidores están dispuestos a adquirir con un precio establecido y un sitio de consumo. (Armstrong & Green, 2006). Para poder suplir esta demanda es necesario administrarla, proyectarla y suplirla. La administración de la demanda puede generar como resultados una mejora en la rentabilidad para la compañía al tener una producción acorde a las necesidades del mercado, obtener gastos de producción y almacenamiento adecuados y evitar agotados.

2.2 Pronostico

Es el arte y la ciencia de predecir los eventos futuros. Puede implicar el empleo de datos históricos y su proyección hacia el futuro mediante algún tipo de modelo matemático. Puede ser una predicción subjetiva o intuitiva; o puede ser una combinación de éstas —es decir, un modelo matemático ajustado mediante el buen juicio del administrador. (Render, 2004).

Los pronósticos dependiendo del enfoque se pueden clasificar en cuantitativos y cualitativos. En las organizaciones se plantean pronósticos económicos, tecnológicos y de la demanda. (Render, 2004) igualmente los pronósticos son a corto plazo menores a 3 meses, mediano plazo entre 3 meses y 3 años y largo plazo superiores a 3 años.

Existen metodologías para generar pronósticos, se debe determinar el producto a pronosticar, el horizonte de tiempo, elegir el modelo a usar y evaluar los resultados finales.

2.3 Regla de Peterson-Silver

Es una prueba que se usa para determinar si una demanda es irregular, la cual se calcula:

$$I = \frac{\sum_{i=1}^n (D_i - \bar{D})^2}{\sum_{i=1}^n D_i}$$

Se debe emplear:

$$V = \frac{\sum_{t=1}^n (D_t - \bar{D})^2}{\sum_{t=1}^n D_t}$$

Donde D_t es la demanda pronosticada discreta para el periodo y n es el horizonte de planeación, los autores (Sipper & Bulfin, 1998) sugieren que la siguiente prueba de irregularidad:

Si $V < 0.25$ el modelo es regular.

Si $V \geq 0.25$ el modelo es irregular

Aplicación de la regla Peterson-Silver para determinar si la demanda de oxígeno medicinal es irregular. (Sipper & Bulfin, 1998)

Aplicando a los consumos 2009, 2010, 2011, 2012 y 2013 se obtiene:

$$V = \frac{27722222}{27722222} = 1$$

$V = 1$

$V \geq 0.25$ Por lo tanto el modelo es irregular.

Aplicación de la regla Peterson-Silver para determinar si la demanda de nitrógeno sector petróleos es irregular. (Sipper & Bulfin, 1998)

Aplicando a los consumos 2009, 2010, 2011, 2012 y 2013 se obtiene:

$$V = \frac{2772222}{2772222} = 1$$

$V = 1$

$V \geq 0.25$ Por lo tanto el modelo es irregular.

2.4 Redes neuronales

Se tiene registro de las primeras investigaciones datan de principios del siglo XIX, pero fue solo hasta mediados del siglo XX que el estudio de las redes neuronales tomo una mayor relevancia gracias al movimiento conexionista, el cual sostenía que el secreto para el aprendizaje y el conocimiento se hallan en axiomas o verdades indiscutibles, que el conocimiento es independiente a la estructura de los símbolos y la representación del conocimiento se hace desde lo más básico y profundo de la inteligencia, el cerebro y particularmente en las neuronas y la infinidad de conexiones presentes entre ellas.(Sierra, 2007)

En el proceso de la construcción de conocimiento sobre este tema se presenta una disminución bastante fuerte debido a los estudios realizados por Minsky y Papert (1969) quienes evidencian las limitaciones de las arquitecturas de redes neuronales usadas para la época y su imposibilidad de resolver una gran variedad de interesantes problemas.

Para los ochentas, el alto avance tecnológico y los conocimientos en la estructura cerebral llevan a un nuevo interés sobre las redes neuronales, llevando a crear un alto número de aplicaciones en distintos campos y con una alta diversidad de propósitos.

2.4.1 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. (Sierra, 2007)

2.4.2 Elementos básicos de las Redes Neuronales

Se denomina procesador elemental o neurona a un dispositivo simple de cálculo que a partir de un vector de entrada procedente del exterior o de otras neuronas, proporciona una única respuesta o salida. (Martín & Sanz, 1997) Los elementos que constituye la neurona son:

Entradas: Provenientes del exterior o de otra neurona, pueden ser binarias o continuas.

Regla de propagación: Permite obtener a partir de las entradas y los pesos el valor del potencial *postsináptico* de la neurona. La función más habitual es la lineal que se basa en la suma ponderada de las entradas con los pesos sinápticos, que

formalmente se puede interpretar como el producto escalar de los vectores de entradas y pesos.

Peso sináptico: Define la intensidad de la interacción de la neurona presináptica j y las postsináptica i . Si el peso es positivo tendera a excitar la neurona postsináptica, si el peso es negativo tendera a inhibirla.

Función de activación: una función lineal o no lineal que limita la amplitud de la salida de la neurona.

Umbral de activación: Es el valor del potencial que al superarlo activa la neurona.

Función de salida: Esta función proporciona la salida global de la neurona, en función de su estado de activación actual. Muy frecuentemente la función de salida es la función identidad $y_i = x_i$, de modo que el estado de activación de la neurona se considera su propia salida.




Figura 11 Modelo genérico de una red neuronal artificial. (Martín & Sanz, 1997)

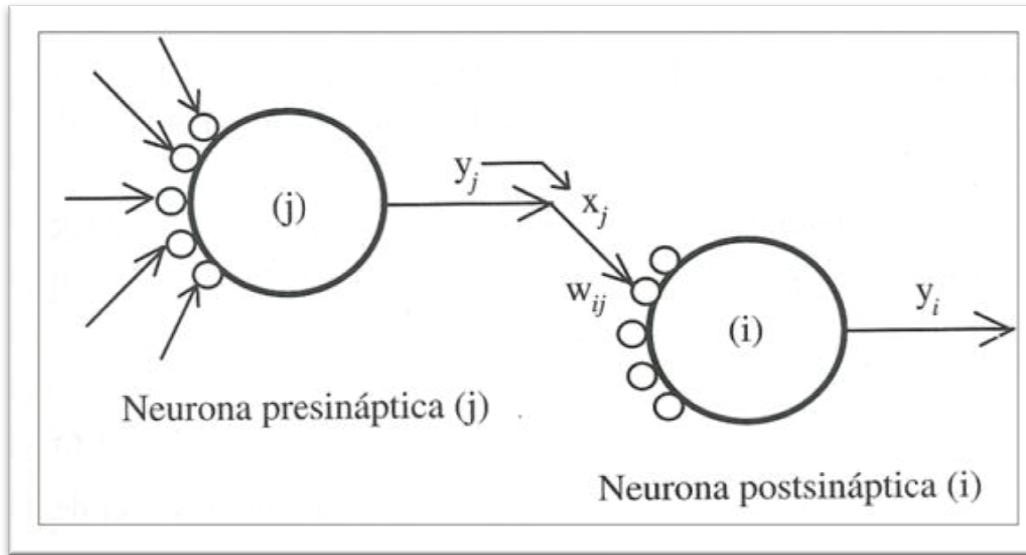


Figura 12 Interconexión entre una neurona presináptica y una postsináptica. (Martín & Sanz, 1997)

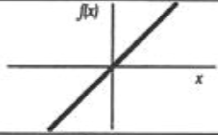

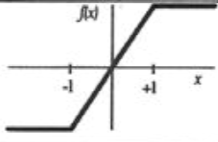
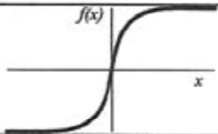
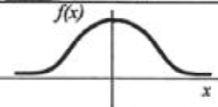
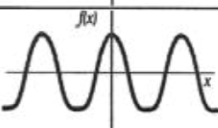
	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Lineal a tramos	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } +l \leq x \leq -l \\ +1, & \text{si } x > +l \end{cases}$	$[-1, +1]$	
Sigmoidea	$y = \frac{1}{1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

Figura 13 Funciones de activación habituales. (Martín & Sanz, 1997)

2.4.3 Arquitecturas de las Redes Neuronales Artificiales.

Se denomina arquitectura a la topología o estructura en la que las distintas neuronas constituyentes de la red neuronal se asocian. En un ANS, los nodos se conectan por medio de sinapsis; esta estructura de conexiones sinápticas determina el comportamiento de la red. Las conexiones sinápticas son direccionales, es decir, la información sólo puede fluir en un sentido (desde la neurona presináptica a la neurona postsináptica). (Martín & Sanz, 1997)

Las neuronas se agrupan en unidades estructurales llamadas capas, donde las neuronas que las componen por lo general son del mismo tipo. El conjunto de una o varias capas conforma una red neuronal. Las capas se dividen en:

Capa de entrada: Compuesta por neuronas que reciben datos del entorno.

Capa oculta: Compuesta por neuronas no están en contacto con el exterior, ni como receptoras ni como ectoras.

Capa de salida: Compuesta por neuronas que proporcionan la respuesta de la red neuronal.

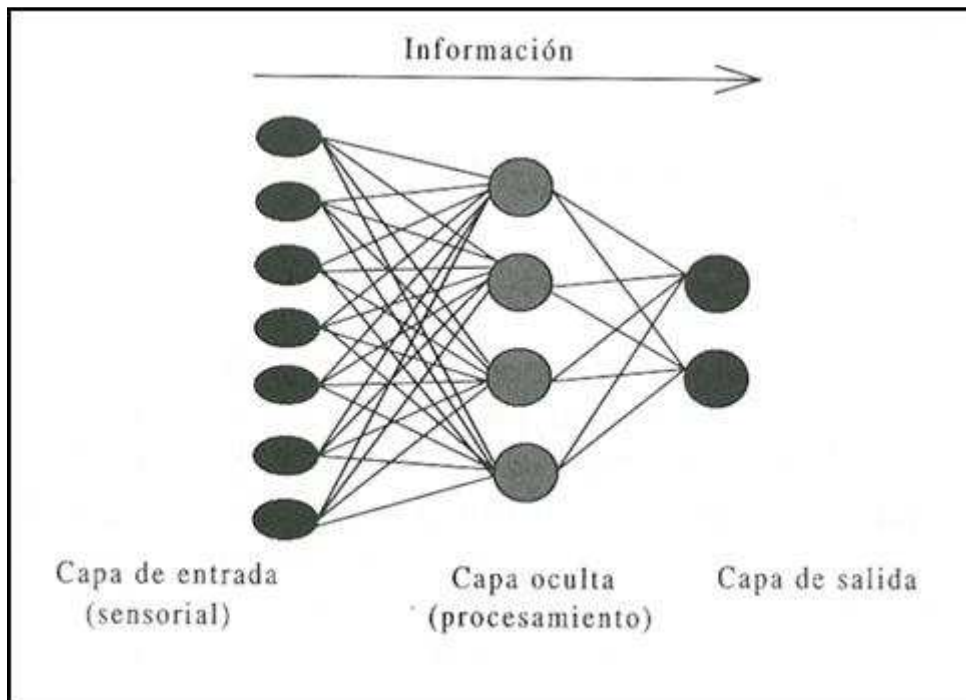


Figura 14 Capas de una red neuronal artificial. (Martín & Sanz, 1997)

Las conexiones entre las neuronas pueden ser clasificadas como conexiones intracapa, las neuronas se conectan con otras neuronas de su misma capa y como conexiones intercapa, las neuronas se conectan con neuronas de diferentes capas.

2.4.4 Clasificación de las redes neuronales artificiales.

Según su arquitectura:

Redes neuronales como Monocapa, que poseen una única capa de neuronas que reciben la información, la procesan y generan una salida.

Redes multicapa que poseen varias capas donde se diferencian las capas de entrada y salida, pueden tener capas ocultas entre estas.

Redes recurrentes que poseen lazos de realimentación entre las diferentes capas, neuronas de la misma capa o entre una misma neurona.

Según su aprendizaje:

Redes de aprendizaje supervisado, donde se presenta a la red un grupo de patrones al igual que la salida deseada, así ella va ajustando sus pesos buscando la salida deseada.

Redes de aprendizaje no supervisado, donde la red no tiene un parámetro de salida y su salida se basa en auto asociación y auto organización.

Redes de aprendizaje híbrido, donde se encuentran los dos tipos de aprendizaje, por lo general se encuentran en diferentes capas.

Redes neuronales de aprendizaje reforzado, Se puede decir que es la mitad del camino del supervisado y el no supervisado, no se suministra explícitamente la salida deseada.

Según su aplicación:

Redes de clasificación, hacen uso del aprendizaje no supervisado para obtener patrones de clasificación con base en las entradas del problema.

Redes de predicción, cuyo objetivo es la modelación de un sistema no lineal.

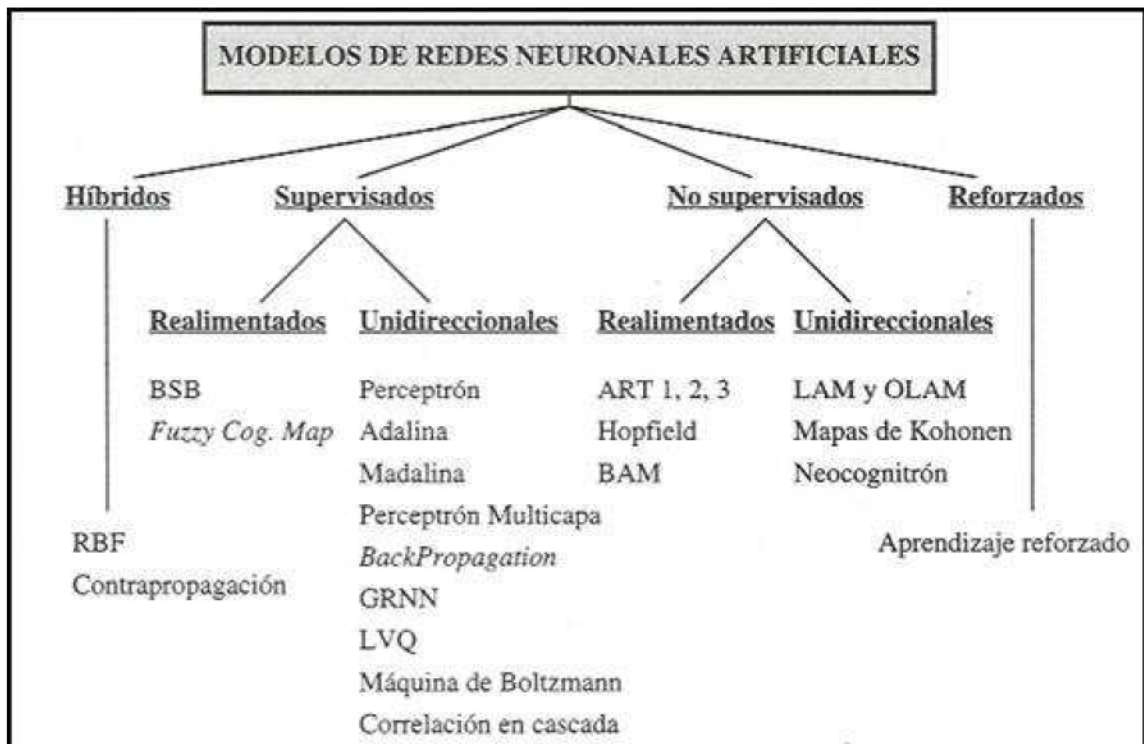


Figura 15 Clasificación de las redes neuronales artificiales por el tipo de aprendizaje y arquitectura. (Martín & Sanz, 1997)

2.5. Métodos de pronóstico

Los pronósticos se basan en dos grandes enfoques, el cualitativo y el cuantitativo.

2.5.1 Métodos cuantitativos

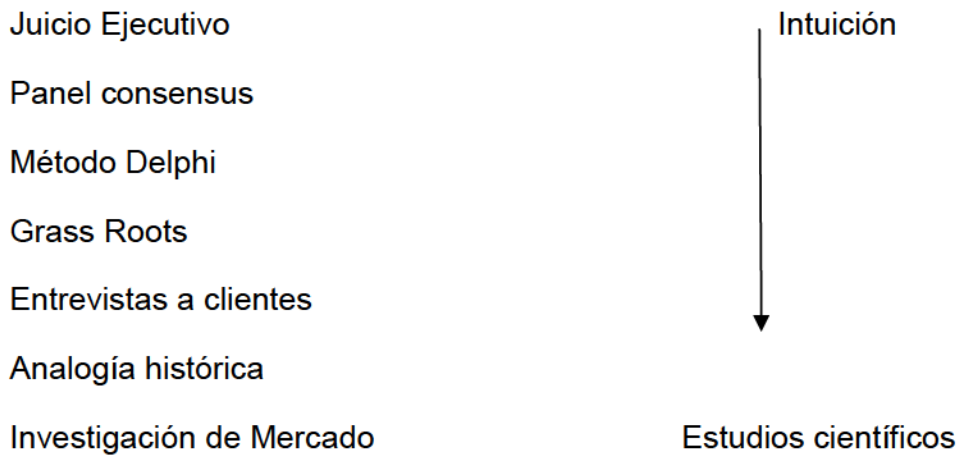
Los modelos cuantitativos de pronósticos son modelos matemáticos que se basan en datos históricos. Estos modelos suponen que los datos históricos son relevantes para el futuro. Casi siempre puede obtenerse información pertinente al respecto. (SIERRA GUERRERO, 2013) Algunas de las técnicas más empleadas son:

- Análisis de series de tiempo
- Promedio móvil simple
- Promedio móvil ponderado
- Suavizamiento exponencial

- Análisis de regresión lineal
- Método Winters
- Técnica de box Jenkins
- Serie de tiempo de Shiskin
- Modelos de simulación

2.5.2 Métodos cualitativos

Estos métodos se emplean cuando el análisis no es claro y no se tienen datos suficientes, estos son algunos métodos empleados:



Y las características de estos métodos son:

Generalmente se basan en juicios o en factores causales relacionados con un producto o servicio en particular

No requiere datos históricos, por lo que son útiles para nuevos productos o servicios.

Los enfoques varían en sofisticación desde encuestas conducidas científicamente a pura intuición.

El enfoque apropiado depende de la etapa del ciclo de vida en que el producto se encuentre.

2.5.3 Redes neuronales

También se hace uso de las redes neuronales artificiales en el pronóstico de la demanda. Estos son algunos de los tipos de redes que se usan para pronosticar:

Perceptrón multicapa

Red de Elman

RBF (Red de Base Radial)

Red de Jordan

Se realiza una descripción de cada una de ellas a continuación:

2.5.3.1 Perceptrón Multicapa.

Esta arquitectura nace de la combinación del trabajo de varios autores y en diferentes épocas en el siglo XX con Werbos en el 74, 88, 89, Parker en el 85 y 87 y Rumelhart en el 86. Ellos buscaban atacar las limitaciones de las primeras arquitecturas como el Perceptrón simple y el *Adalaine* frente a la imposibilidad de la separabilidad de funciones no lineales.

Una de las grandes ventajas y bondades de este tipo de arquitectura es entre otras es que es un aproximador universal, así cualquier función continua en el espacio real puede aproximarse mediante un Perceptrón multicapa, esto fue demostrado en 1989 por Cybenko y Hornik, (Martín & Sanz, 1997), adicional posee una alta capacidad de generalización y robustez lo que ayuda a no afectar el resultado en el caso que se presenten pérdidas de neuronas.

Esta arquitectura presenta en algunos casos un elevado tiempo de entrenamiento cuando los problemas son demasiado complejos, pero esto no impide en que sea ampliamente usado en campos como:

- Reconocimiento de imágenes
- El control de procesos
- Predicción de series temporales
- Conducción de vehículos y aeronaves
- Identificación de tendencias




Figura 16 Perceptrón Multicapa. (Martín & Sanz, 1997)

2.5.3.2 Red Elman – Jordan

Esta arquitectura llamada así por los investigadores que las desarrollaron tiene como característica que son parcialmente recurrentes, poseen conexión *feed-forward* y algunas conexiones hacia atrás.

Estas redes funcionan en principio igual que un Perceptrón multicapa, pero algunas de las entradas son alimentadas por respuestas de neuronas de las capas ocultas o de neuronas de la capa de salida.




Figura 17 Redes de arquitectura Elman y Jordan. ("http://www.disa.bi.ehu.es/spanish/profesores-etsi-bilbo/~jtpcaaxi/PFC/wwwANN/arquitectura_archivos/image012.gif," 2013)

2.5.3.3 Redes de base radial

Este tipo de redes creadas a mediados de los años 80 por M.J.D. Powell, D.S. Broomhead y D. Lowe, plantean un funcionamiento que no es común a las otras arquitecturas.

Esta arquitectura posee únicamente una capa oculta, así que solo podrán tener como máximo 3 capas, una de entrada, la oculta y la de salida. Cada neurona de una capa tiene conexión con todas las neuronas de la siguiente capa y no existen pesos de la entrada a las neuronas de la capa oculta.

La principal diferencia es el funcionamiento de las neuronas, mientras en que en las redes multicapa las neuronas se activan por saturación las redes de base radial se define un centro para cada neurona de la capa oculta, así cuando las entradas están cercanas a ese centro toman un alto valor de activación y es menor a mayor distancia del centro.

El entrenamiento de esta arquitectura consiste en distribuir las neuronas a lo largo de toda la capa de entrada, así todas serán capaces de lograr la función deseada, aportando cada neurona una parte de dicha función.

Los centros de las neuronas son calculados con algoritmos específicos que cumplen esta función, o también es posible hacer uso de algoritmos de retro propagación para entrenarlas.

Son de rápido entrenamiento y buen desempeño para problemas pequeños ya que al tener una sola capa de oculta, si las entradas aumentan las neuronas ocultas se incrementan exponencialmente y es muy dispendioso su manejo.




Figura 18 Red Radial. (http://softwarelibre.unsa.edu.ar/docs/descarga/2003/curso/htmls/redes_neuronales/x185.html, 2003)

2.6 Casos de estudio

Los casos de estudio relacionados en la literatura y similares al problema se relacionan a continuación.

2.6.1 Predicción de la demanda eléctrica horaria mediante RNA (Curtis, Persson, & Shore, 2003)

El problema a abordar es lograr generar una predicción de la demanda eléctrica horaria mediante el uso y aplicación de redes neuronales artificiales.

Se hizo uso de una red de 3 capas, una de entrada, una oculta y una de salida. En la entrada se encuentran 6 neuronas que recibirán cada una de las diferentes variables que intervienen en el proceso y una sola neurona en la capa de salida que indicara el valor de la demanda eléctrica asociada a una hora específica.

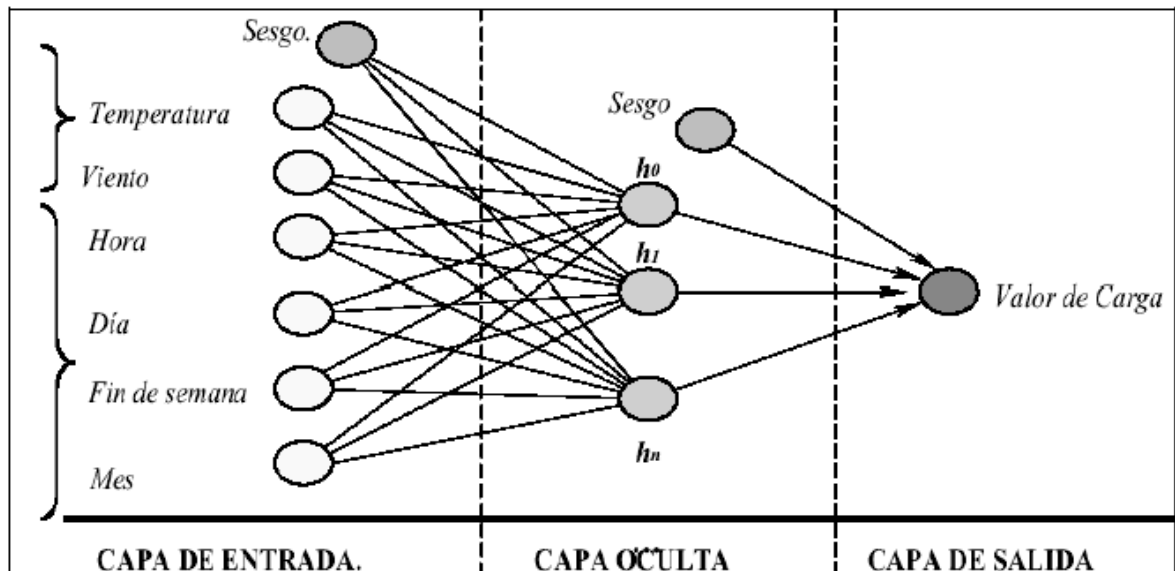


Figura 19 Arquitectura de la RED

Para determinar el número óptimo de neuronas en la capa oculta se llevó a cabo mediante un proceso de ensayo y error.

En el desarrollo de la solución se encontraron las siguientes variables que intervienen en el proceso.

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 ¹⁰	Numérica. Representada por su valor actual.

Tabla 5 Variables de entrada para la predicción de demanda eléctrica.

Algunas de las variables más difíciles de conseguir fueron las climáticas como temperatura y velocidad del viento, estas se lograron obtener de las páginas Web de NOAA (*National Oceanic and Atmospheric Administration*) y de ATDD (*Atmospheric Turbulence and Diffusion Division*).

Para entrenar la red se hizo uso de 8760 observaciones. Se identificó igualmente que la reducción del error cuadrático medio es despreciable a partir de las 200 iteraciones.

Este es el resumen de los datos óptimos de entrenamiento:

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

Tabla 6 Valores óptimos para el entrenamiento de la RNA.

Luego de realizar el entrenamiento de la red se obtuvo gráficamente el siguiente resultado:

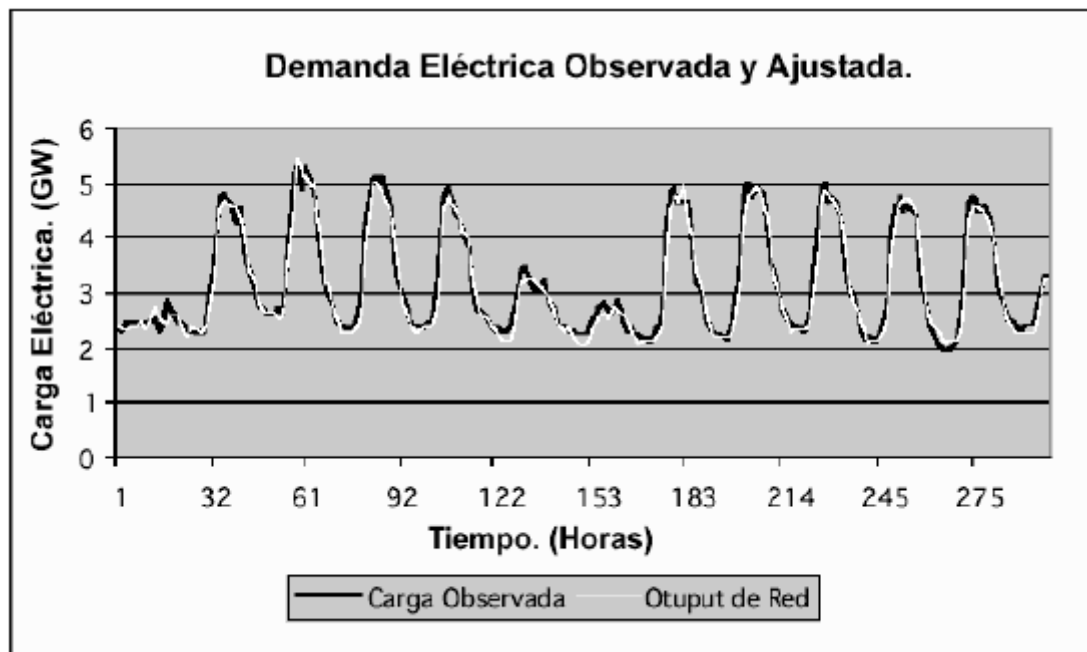


Figura 20 Respuesta de la RNA entrenada frente a la muestra inicial

Realizando una revisión del gráfico obtenido se puede ver con claridad el buen desempeño de la red, intuitivamente se puede concluir que su comportamiento es bueno. El error cuadrático medio es de un 0,6% lo que lleva a concluir que el entrenamiento ha sido exitoso.

Se presenta a la RNA una serie de datos no conocidos para ella y así poder observar el desempeño para emplearla en un futuro pronóstico, en este caso la red generara un pronóstico con las relaciones previamente aprendidas las cual

nosotros podemos comparar con datos reales y así contrastar la eficiencia del modelo.




Figura 21 Respuesta de la RNA entrenada frente a datos desconocidos.

Gráficamente se puede observar el comportamiento de la RNA frente a datos no conocidos, generando un pronóstico bastante acertado. Numéricamente se encontró que el error cuadrático medio es de 0.92% siendo lo suficientemente reducido para admitir la confiabilidad del modelo de pronóstico.

Una vez se obtienen los datos del pronóstico se procede a comparar el resultado con otros métodos de pronóstico, se concluye luego de la comparación que el método de RNA supera ampliamente a otras técnicas de modelación y predicción, se compara con los siguientes modelos:

Modelo ingenuo. Modelo auto regresivo de primer orden,

$$y_t = y_{t-1} + \varepsilon \quad \varepsilon \approx N(0, \sigma)$$

ARMA. Hemos identificado un modelo $ARMA(2,2) \times ARMA(24,24)$

Alisado Exponencial. Alisado exponencial de Holt-Winters con $\alpha=0.5$

	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 7 Resultados de la comparación entre modelos de pronóstico.

2.6.2 Aplicación de RNA en el análisis de datos: comparación entre RNA y modelos estadísticos clásicos. (Moreno, 2002)

Haciendo una revisión de la aplicación de las RNA en el análisis de datos se toman 549 muestras que se ocupan de una comparación de las RNA y otros métodos como estadísticos, sistemas expertos, etc. El análisis se centrara en 380 estudios que realizan comparaciones específicas contra modelos estadísticos. A la vez se dividen en comparaciones teóricas, 32 trabajos y comparaciones empíricas 348 trabajos.

A lo largo de la década de los 90, una vez reconocido el campo de las RNA ante la comunidad científica, surgieron una serie de trabajos teóricos cuya comparación entre RNA y estadística pone de manifiesto la similitud y, en muchos casos, la identidad entre ambas perspectivas.

Uno de los aspectos que han fomentado la idea errónea acerca de las diferencias entre RNA y estadística versa sobre la terminología utilizada en la literatura de ambos campos. Recordemos que el campo de las RNA surge como una rama de la IA con una fuerte inspiración neurobiológica y su desarrollo ha sido debido a la contribución de investigadores procedentes de una gran variedad de disciplinas. A continuación se muestra una comparación de terminologías y entre modelos estadísticos y de redes neuronales.

Terminología estadística	Terminología de redes neuronales
Observación	Patrón
Muestra	Datos de entrenamiento
Muestra de validación	Datos de validación, test
Variables explicativas	Variables de entrada
Variable de respuesta	Variable de salida
Modelo	Arquitectura
Residual	Error
Error aleatorio	Ruido
Estimación	Entrenamiento, aprendizaje
Interpolación	Generalización
Interacción	Conexión funcional
Coefficientes	Pesos de conexión
Constante	Peso umbral
Regresión y análisis discriminante	Aprendizaje supervisado o heteroasociación
Reducción de datos	Aprendizaje no supervisado o autoasociación
Análisis de cluster	Aprendizaje competitivo

Tabla 8 Equivalencia en terminología estadística y redes neuronales. (Moreno, 2002)

Modelo estadístico	Modelo de red neuronal
Regresión lineal múltiple	Perceptrón simple con función lineal
Regresión logística	Perceptrón simple con función logística
Función discriminante lineal	Perceptrón simple con función umbral
Regresión no lineal múltiple	Perceptrón multicapa con función lineal en la salida
Función discriminante no lineal	Perceptrón multicapa con función logística en la salida
Análisis de componentes principales	Regla de Oja
Análisis de clusters	Perceptrón multicapa autoasociativo
K vecinos más cercanos	Mapas autoorganizados de Kohonen
Regresión kernel	Learning Vector Quantization (LVQ)
	Funciones de Base Radial (RBF)

Tabla 9 Equivalencia de modelos estadísticos y modelos de red neuronal.

A través de una comparación teórica entre los modelos se encuentran similitudes que nos permiten compararlas en su estructura más no en sus resultados.

2.6.3 Demanda energética a mediano plazo pronosticada a través de modelos Neuro Fuzzy. (Iranmanesh, Abdollahzade, & Miranian, 2011)

La investigación se basó en un pronóstico a través de modelos Neuro Fuzzy para aplicar al consumo de gasolina, crudo y gas natural en un periodo de 12 meses.

La demanda energética del mundo va creciendo a medida que la población también crece, un ejemplo claro es que el consumo del petróleo en Estados Unidos, uno de los mayores consumidores del mundo de recursos energéticos aumento su consumo de petróleo en un 20.4% desde 1990 a 2005. El consumo de gas natural en el mismo periodo aumento en un 16.32%. Las autoridades necesitan buscar la manera de proveer la demanda energética, especialmente a largo plazo lo más preciso posible para planear la generación y distribución.

A lo largo de las últimas décadas se han desarrollado diferentes métodos de pronóstico para la demanda energética, uno de los más populares basados en series de tiempo es el ARIMA, y algunas variaciones de este modelo.

Cuando se comienzan a presentar sistemas no lineales el pronóstico comienza a fallar y es donde se optaron por técnicas de inteligencia computacional que tienen

un alto rendimiento en la modelación y pronóstico de sistemas no lineales como son las Redes Neuronales Artificiales y los sistemas Fuzzy.

En el estudio se usó un sistema híbrido entre sistemas Fuzzy y RNA con base radial aplicando el algoritmo resultante a la demanda mensual de la gasolina en Japón, USA, Kuwait, Canadá e Irán obteniendo los siguientes resultados.




Figura 22 Estructura Sistema Neuro-Fuzzy

Se realizaron identificación de las entradas críticas al sistema y los periodos con que se cuentan datos.

Case Study	Input Features	
Gasoline demand	Auto regression part	Gasoline demand historical
	Cross regression part	Population GDP Gasoline price
Crude oil demand	Auto regression part	Crude oil demand historical
	Cross regression part	Population GDP Crude oil import price
Natural gas demand	Auto regression part	Natural gas demand historical
	Cross regression part	Population GDP Natural gas price
		Average heating degree-days

Tabla 10 Variables de entrada para el pronóstico de la demanda energética.

Se realiza el pronóstico obteniendo resultados con un error en el caso de la gasolina:




Figura 23 Demanda Gasolina vs pronóstico de la demanda de Gasolina.

Actual	Forecast	APE %
8.52	8.58	0.76
8.58	8.68	1.18
8.79	8.84	0.54
9.11	8.92	2.1
9.16	9.02	1.53
9.31	9.05	2.79
9.3	9.27	0.33
9.26	9.29	0.3
9.11	8.9	2.29
9.02	8.93	0.99
8.82	8.86	0.48
8.910	8.907	0.03

Tabla 11 Comparación demanda vs pronóstico de la gasolina

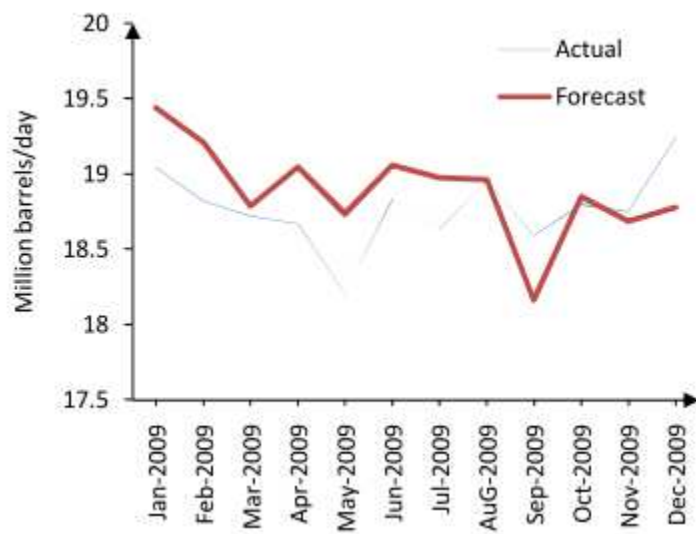


Figura 24 Demanda petróleo vs pronóstico demanda petróleo año 2009.

Actual	Forecast	APE %
19.04	19.44	2.1
18.82	19.21	2.08
18.72	18.79	0.37
18.67	19.05	2.02
18.21	18.73	2.87
18.83	19.06	1.21
18.63	18.97	1.85
18.95	18.96	0.06
18.59	18.16	2.3
18.8	18.85	0.26
18.75	18.69	0.33
19.24	18.78	2.39

Tabla 12 Comparación demanda vs pronóstico del petróleo.




Figura 25 Demanda gas natural vs pronóstico demanda Gas natural 2008

Actual	Forecast	APE %
88.17	81.48	7.58
86.3	82.37	4.55
73.46	69.99	4.73
60.77	58.79	3.25
50.83	50.48	0.69
53.45	54.02	1.07
55.1	53.91	2.16
54.27	56.88	4.81
48.67	49.94	2.6
52.75	51.87	1.66
62.27	60.97	2.08
77.38	75.23	2.77

Tabla 13 Comparación demanda vs pronóstico del Gas natural.

El estudio presenta unos resultados favorables en la aplicación de la identificación de tendencias y comportamientos cíclicos no lineales bajo el uso de sistemas híbridos Neuro Fuzzy. En el trabajo se pree la demanda en 3 años diferentes y se obtienen resultados que indican que el enfoque propuesto es válido para su uso en la previsión de la demanda energética.

El campo de las aplicaciones de pronóstico de la demanda con modelos de redes neuronales es amplio y aplicado a una gran cantidad de productos y servicios obteniendo excelentes resultados. No se encontró aplicaciones a los productos como oxígeno para aplicaciones medicinales, nitrógeno para aplicaciones de producción de petróleo o soldadura en general, todos estos productos enmarcados en el mercado Colombiano con sus componentes sociales, económicos y climáticos.

2.6.4 Evaluación comparativa entre métodos de pronóstico.

Existen varios criterios que permiten realizar evaluar y comparar métodos de pronósticos de la demanda. Para la evaluación de los métodos de pronósticos se hará uso de los criterios expuestos por Norman Gaither y Greg Frazier. (GAITHER & FRAIZER, 2000)

Los autores proponen 6 criterios de comparación para métodos de pronóstico: Costo, precisión, Datos disponibles, Tiempo, naturaleza de productos y servicios, respuesta de impulso y amortiguación del ruido. Estos criterios no hacen

referencia para aplicarlos a algún tipo o grupo de productos específicos, por esta razón podemos hacer uso de ellos en los productos de estudio del presente trabajo.

Costo: Este elemento va ligado a la precisión, para obtener mayor precisión se debe incurrir en un mayor costo, los costos se pueden discriminar en complejidad, número de datos, dificultad para desarrollar el modelo, software necesario.

Cuantificando este factor el costo en el pronóstico puede ser bajo, medio o alto.

Precisión: Para obtener una mayor precisión es necesario tener un mayor costo, que se refleja en un mayor número de datos y complejidad de los modelos, mayores costos para ponerlos en marcha y dificultad en su operación.

Cuantificando este factor la precisión puede ser Muy precisa, Precisa, de Baja precisión.

Datos disponibles: Son los datos disponibles y fundamentales para el pronóstico, son relevantes al momento de elegir el método de pronóstico. Se debe identificar la cantidad, la exactitud, la relevancia de los datos, su confiabilidad, etc.

Cuantificando este factor se puede decir que es bajo, medio o alto.

Tiempo: Se refiere al periodo sobre el cual se ejecutara el pronóstico, por lo general depende de la naturaleza del pronóstico:

Corto plazo (1-3 meses)

Medio plazo (>3 meses y < 3 años)

Largo plazo (≥ 3 años)

Naturaleza de los productos y servicios: Es aconsejable que los responsables hagan uso de diferentes métodos de pronóstico para productos distintos. Factores como si el producto es un bien o servicio, su costo, ciclo de vida influyen en la elección del método del pronóstico.

Respuesta de impulso y amortiguación de ruido: Es necesario realizar un equilibrio entre lo que deseamos del modelo de pronóstico con respecto a su respuesta, como por ejemplo ante el cambio de datos reales de la demanda contra nuestro deseo de suprimir cualquier variación aleatoria indeseable, ósea ruido en los datos.

Se encuentran otros criterios de selección propuestos por Schroeder tomando como base a Wheelwright y Clakree, estos criterios son: (Cintado, 2009) sofisticación del usuario y del sistema, tiempo y recursos disponibles,

Uso o características de la decisión, Disponibilidad de datos y patrón de datos.

Se amplían los criterios que no se han revisado hasta el momento:

Sofisticación del usuario y del sistema: Se ha encontrado que el método de pronóstico debe ajustarse a los conocimientos y sofisticación del usuario, los gerentes se rehúsan a utilizar métodos que no comprenden y la tendencia de los métodos de pronóstico es a una mayor sofisticación y complejidad con el paso del tiempo.

Patrón de los datos: El patrón de datos afectará el tipo de método. Si la serie de tiempo es plana, se utilizarán métodos de primer orden, si existen tendencias o patrones de estacionalidad se necesitarán métodos más avanzados.

Se pueden encontrar patrones de datos con tendencia, estacionales o Cíclicos.

Con estos parámetros se procede a cuantificarlos, se genera una relación de valores versus características, luego se compararan los métodos entre sí.

Costo: Se desea preferiblemente un método que tenga bajo costo, se cuantificara con costo bajo =1, medio=0.5 y alto=0.

Precisión: Se desea preferiblemente un método Muy preciso, se cuantificara con precisión Muy preciso=1, Precisa=0.5 y Baja precisión=0.

Datos disponibles: Se desea un método con baja cantidad de datos disponibles, se cuantificara datos disponibles Bajo=1, Medio=0.5 y Alto=0.

Tiempo: Se desea tener un pronóstico a mediano plazo, entre 3 meses y 3 años, se cuantificara el Tiempo en Mediano Plazo=1, Corto plazo=0.5 y largo plazo=0.

Respuesta al impulso y amortiguación de ruido: Se debe tener un método que permita presencia de ruido a las entradas. Se cuantificara Acepta ruido a las entradas=1, No acepta ruido a las entradas=0.

Patrón de datos: Se desea un método que acepte todos los patrones de datos, Se cuantificara así: Estacionarios=0, Tendencia=0.25, Cíclicos=0,25, Si acepta combinaciones de dos tendencias se asignara=0,5, si se pueden combinar las 3 tendencias se asigna =1.

Tipo de modelo: Se define si el modelo es lineal o no lineal, se cuantificara como Modelo no Lineal=2, Modelo Lineal=0. Se considera este factor crítico por eso la puntuación se diferencia de los demás parámetros.

Se construye a continuación una tabla resumen de los parámetros de comparación y su cuantificación.

Criterio	Cuantificación	Descripción	Valor
Costo	Bajo	Método de bajo costo	1
	Medio	Método de Mediano costo	0,5
	Alto	Método de Alto costo	0
Precisión	Muy precisa	Método con resultados muy confiables	1
	Precisa	Método con resultados confiables	0,5
	Baja de precisión	Método con resultados poco confiables	0
Datos Disponibles	Bajo	Método necesita muy pocos datos	1
	Medio	Metodo necesita pocos datos	0,5
	Alto	Metodo necesita muchos datos	0
Tiempo	Mediano plazo	Método entre 3 meses y 3 años	1
	Corto plazo	Metodo menor a 3 meses	0,5
	Largo plazo	Metodo mayor a 3 años.	0
Respuesta al impulso y amortiguación de ruidos	Si	El método si acepta ruido en las entradas	1
	No	El método no acepta ruido en las entradas	0
Patron de datos	Estacionarios	Método con soporte de datos de tipo Estacionario	0
	Tendencia	Método con soporte de datos de tipo Tendencia	0,25

	Cíclicos	Método con soporte de datos de tipo Cíclicos	0,25
	Estacionarios y Tendencia	Método con soporte de datos de tipo Estacionarios y Tendencia	0,5
	Estacionarios y Cíclicos	Método con soporte de datos de tipo Estacionarios y Cíclicos	0,5
	Tendencia y Cíclicos	Método con soporte de datos de tipo Tendencia y Cíclicos	0,5
	Estacionarios, Tendencia y Cíclicos	Método con soporte de datos de tipo Estacionarios, Tendencia y Cíclicos	1
Tipo de modelos	Lineal	Método no soporta funciones no lineales	0
	No Lineal	Método soporta funciones no lineales	2

Tabla 14 Parámetros de evaluación y comparación de métodos de pronóstico.

Se genera un cuadro comparativo de cada uno de los métodos, basados en sus principales características. Si no se tiene información clara y suficiente para cuantificar una característica esta no se calificara y tomara un valor de cero. Con esto se buscara obtener la metodología más conveniente para aplicarla al pronóstico de nitrógeno con uso en la exploración y explotación petrolera y oxígeno con fines de uso medicinal.

Criterio	Métodos cuantitativos	Análisis Series de tiempo	Promedio móvil simple	Promedio móvil ponderado	Suavización exponencial	Análisis de regresión lineal	Métodos cualitativos	Redes neuronales
Costo	Alto	Bajo	Bajo	Bajo	Alto	Bajo	Alto	Medio
Precisión	Baja de precisión	Precisa	Precisa	Precisa	Precisa	Precisa	S/D	Muy Precisa
Datos Disponibles	Alto	Alto	Medio	Medio	Bajo	Alto	S/D	Medio
Tiempo	Mediano plazo	Corto plazo	Corto plazo	Corto plazo	Corto plazo	Largo plazo	Largo plazo	Mediano plazo
Respuesta al impulso y amortiguación de ruidos	No	No	No	No	No	No	No	Si
Patron de datos		Estacionarios, Tendencia y Cíclicos	Estacionarios y Tendencia	Estacionarios y Tendencia	Tendencia	Tendencia	Estacionarios, Tendencia y Cíclicos	Estacionarios, Tendencia y Cíclicos
Tipo de modelos	Lineal	Lineal	Lineal	Lineal	Lineal	Lineal	S/D	No lineal

Tabla 15 Comparación de métodos criterio a criterio cualitativamente.

Criterio	Métodos cuantitativos	Análisis Series de tiempo	Promedio móvil simple	Promedio móvil ponderado	Suavización exponencial	Análisis de regresión lineal	Métodos cualitativos	Redes neuronales
Costo	0	1	1	1	0	1	0	0,5
Precisión	0	0,5	0,5	0,5	0,5	0,5	0	1
Datos Disponibles	0	0	0,5	0,5	1	0	0	0,5
Tiempo	1	0,5	0,5	0,5	0,5	0	0	1
Respuesta al impulso y amortiguación de ruidos	0	0	0	0	0	0	0	1
Patron de datos	0	1	0,5	0,5	0,25	0,25	1	1
Tipo de modelos	0	0	0	0	0	0	0	1
Gran Total	1	3	3	3	2,25	1,75	1	6

Tabla 16 Comparación de métodos criterio a criterio cuantitativamente.

Luego de la comparación realizada se opta por las características del problema en usar Redes Neuronales Artificiales para el pronóstico.

2.6.5 Evaluación comparativa entre diferentes arquitecturas de redes neuronales para el pronóstico.

Una red neuronal se caracteriza principalmente de su arquitectura y el tipo de aprendizaje. Dentro del tipo de aprendizaje se encuentran los supervisados, no supervisados, híbridos y otros. Por parte de la arquitectura se encuentran las unidireccionales o las realimentadas.

Los estudios concluyen que las mejores redes neuronales para la ejecución de pronósticos son las supervisadas, no se especifica qué tipo de arquitectura, así que para el desarrollo del problema la evaluación se realizara con Redes neuronales de este tipo buscando la más apta para resolver el problema planteado.

2.6.5.1 Criterios para la comparación de redes neuronales.

Para realizar la evaluación de criterios y comparación se toman aspectos fundamentales que nos permiten cuantificarlos y compararlos entre sí, los criterios que se toman para la evaluación son: Error mínimo, Convergencia, Grado de complejidad de la red, Robustez, Tiempo para el entrenamiento.

Error mínimo: Compara la salida de la red vs el teórico que debería entregar la red, este factor se debe reducir por medio de iteraciones buscando llegar al mínimo. Se cuantifica con bajo = 3 y alto = 1. Se necesita un bajo nivel de error.

Convergencia: Consiste en encontrar los parámetros óptimos para que la red logre la función deseada. Cuando más rápido se minimiza el error más rápida es la convergencia. Se cuantifica con Alto = 3 y bajo = 0. Si no se presenta convergencia la Red no obtendrá los resultados esperados.

Grado de complejidad de la red: Se compone del número de capas, entradas, conexiones entre nodos, los cuales pueden dar como resultado una no convergencia de la red o un sobreajuste que no generaliza los nuevos datos. Se cuantifica bajo = 2, alta = 1. Se busca una menos complejidad.

Robustez: Es la capacidad de continuar la operación frente a fallas, perdida de entradas o presencia de ruido en las entradas. Se cuantifica con alta = 5 y baja = 1. La red debe soportar ruido y fallas.

Tiempo de entrenamiento: Es todo el tiempo empleado en la configuración de la arquitectura, la obtención de los parámetros, búsqueda de pesos y criterios de

parada de entrenamiento. Se cuantifica Bajo = 3 y Alto = 1. Se espera que el tiempo de entrenamiento sea bajo.

A continuación se presenta la tabla con los parámetros cuantificados para la comparación de redes neuronales.

Criterio	Cuantificación	Descripción	Valor
Error Mínimo	Bajo	Cuando el error de la salida de la RNA comparado con la salida esperada es bajo.	3
	Alto	Cuando el error de la salida de la RNA comparado con la salida esperada es alto.	0
Convergencia	Alto	Alta reducción del error para aproximarse a la función deseada	3
	Bajo	Baja reducción del error para aproximarse a la función deseada	0
Grado de complejidad de la red	bajo	Red de fácil manejo y buena convergencia	2
	Alto	Red de difícil manejo y regular convergencia	1
Robustez	Alta	Una alta resistencia a continuar y dar buenos resultados frente a fallas y ruido en las	5

		entradas.	
	Baja	Una baja resistencia a continuar y dar buenos resultados frente a fallas y ruido en las entradas.	1
Tiempo de entrenamiento	Bajo	Obtención de pesos y parámetros de la red en un tiempo bajo	3
	Alto	Obtención de pesos y parámetros de la red en un tiempo alto	1

Tabla 17 Parámetros de evaluación y comparación de redes neuronales.

Se procede a comparar 4 tipos de arquitecturas expuestos en capítulos anteriores.

Criterio	Perceptrón Multicapa	Red de Elman	Red de Jordan	Red de base radial
Error mínimo	Bajo	Bajo	Bajo	Bajo
Convergencia	Alto	Alto	Alto	Alto
Grado de complejidad de la red	Bajo	Alto	Alto	Alto
Robustez	Alta	Baja	Baja	Baja
Tiempo de entrenamiento	Bajo	Alto	Alto	Bajo

Tabla 18 Comparación de RNA criterio a criterio cuantitativamente

Criterio	Perceptrón Multicapa	Red de Elman	Red de Jordan	Red de base radial
Error mínimo	3	3	3	3
Convergencia	3	3	3	3
Grado de complejidad de la red	2	1	1	1
Robustez	5	1	1	1
Tiempo de entrenamiento	3	1	1	3
Total	16	9	9	11

Tabla 19 Comparación de RNA criterio a criterio cuantitativamente.

Se concluye que la mejor arquitectura para realizar el pronóstico del problema es el Perceptrón multicapa, esto afirma la condición de aproximador universal planteado en el marco teórico.

2.7 Software para pronosticar basados en redes neuronales artificiales.

En la actualidad se encuentran varios software para pronósticos basados en redes neuronales artificiales, estos software funcionan bajo diferentes plataformas, igualmente son independientes o dependientes de otros software como Excel.

2.7.1 Neuro Shell. <http://www.neuroshell.com/>

Un software con una buena interface gráfica, enfocado para la predicción de Stocks de almacenamiento, consumo de *commodities* y FOREX. Este Software ha sido nombrado 11 veces como el mejor del año en *Technical Analysis of Stocks and Commodities Readers' Choice Awards*.

Su precio es de \$ 3.495 USD.

2.7.2 Neural Network Forecasting Software by BI3S lab. <http://www.bis-lab.com/neural-network-software.htm>

Es un software de origen alemán, que hace uso de métodos de inteligencia artificial entre las cuales se encuentran las redes neuronales artificiales. El software contempla el análisis de series de tiempo, creación de pronósticos y evaluación de pronósticos.

El software ha sido desarrollado desde 2004 y ha sido empleado en el pronóstico de ratings de televisión en Inglaterra, pronósticos en fabricación de textiles y movimientos de consumidores en Alemania obteniendo muy buenos resultados.

Posee un buen entorno gráfico y buen número de algoritmos de entrenamiento.

Su precio es de €5.000 EU

2.7.3 GMDH Shell www.gmdhshell.com/neural-network-software

Un software usado por más de 400.000 personas alrededor del mundo con un entorno gráfico bastante desarrollado, de fácil uso gracias a la herramienta de manejo incluida y modelos pre-configurados para una rápida evaluación.

Tiene como ventaja la exportación de los resultados a Excel para una posterior evaluación y análisis de resultados.

Su precio está entre \$999 y \$4.999 USD dependiendo del número de licencias.

2.7.4 Alyuda Forecaster XL <http://www.alyuda.com/forecasting-excel-software-with-neural-network.htm>

Es un software de que funciona directamente en las hojas de cálculo de Excel, permitiendo la manipulación de los datos directamente y todas las otras funciones de Excel.

El software se incorpora como un complemento desde el cual se puede elegir la arquitectura, tipo de variables y entrenamiento a realizar.

Su precio es de \$997 USD

2.7.5 Neural Tools for Excel Palisade. <http://www.palisade-ta.com/neuraltools/>

Un software que trabaja en Excel, es un potente software que entrenar la red con los datos, probar la precisión de la red y hacer pronósticos con los nuevos datos en un solo paso. *NeuralTools* puede actualizar automáticamente los pronósticos cuando cambian los datos de entrada, para que no tenga que ejecutar de nuevo manualmente los pronósticos cuando obtenga los nuevos datos, todo sin salir de Excel.

El software viene en dos versiones, la profesional que permite el ingreso hasta de 1.000 datos y el industrial que tiene la capacidad de ingresar datos de manera ilimitada.

Su precio es de \$795 USD incluye un año de mantenimiento y actualizaciones.

2.7.6 Matlab® www.matlab.com

MATLAB® es un lenguaje de alto nivel y un entorno interactivo para el cálculo numérico, la visualización y la programación. Mediante MATLAB®, es posible analizar datos, desarrollar algoritmos y crear modelos o aplicaciones. El lenguaje, las herramientas y las funciones matemáticas incorporadas permiten explorar diversos enfoques y llegar a una solución antes que con hojas de cálculo o lenguajes de programación tradicionales, como pueden ser C/C++ o Java™.

MATLAB® se puede utilizar en una gran variedad de aplicaciones, tales como procesamiento de señales y comunicaciones, procesamiento de imagen y vídeo, sistemas de control, pruebas y medidas, finanzas computacionales y biología computacional. Más de un millón de ingenieros y científicos de la industria y la educación utilizan MATLAB®, el lenguaje del cálculo técnico.

MATLAB® contiene diferentes *Toolbox* de diferentes aplicaciones, una de ellas es el *Neuronal Network Toolbox*, que es la herramienta para uso, aprendizaje y aplicación de las redes neuronales.

Este software presenta una amplia variedad de configuraciones y aplicaciones de las redes neuronales.

Este software cuenta con varias versiones, se encuentra para uso de estudiantes, universidades e industrial.

El precio en versión estudiante es de \$89 USD.

La universidad EAFIT cuenta con licencia para el uso de este software.

Frente a las diferentes opciones en el mercado y acceso a diferentes software se empleara a MATLAB® para el desarrollo de la presente tesis.

3. Diseño de la RNA para el pronóstico de Oxígeno líquido medicinal y nitrógeno líquido para uso del sector petrolero.

En el presente capítulo se realizará un análisis de las variables de entrada, la construcción de la RNA, se recopilarán datos, se probarán diferentes arquitecturas y se elegirá la más adecuada para la solución del problema.

3.1 Descripción gráfica del procedimiento para la generación del pronóstico.

A continuación se propone a manera de flujo el proceso para la elaboración del pronóstico de los productos del problema planteado.

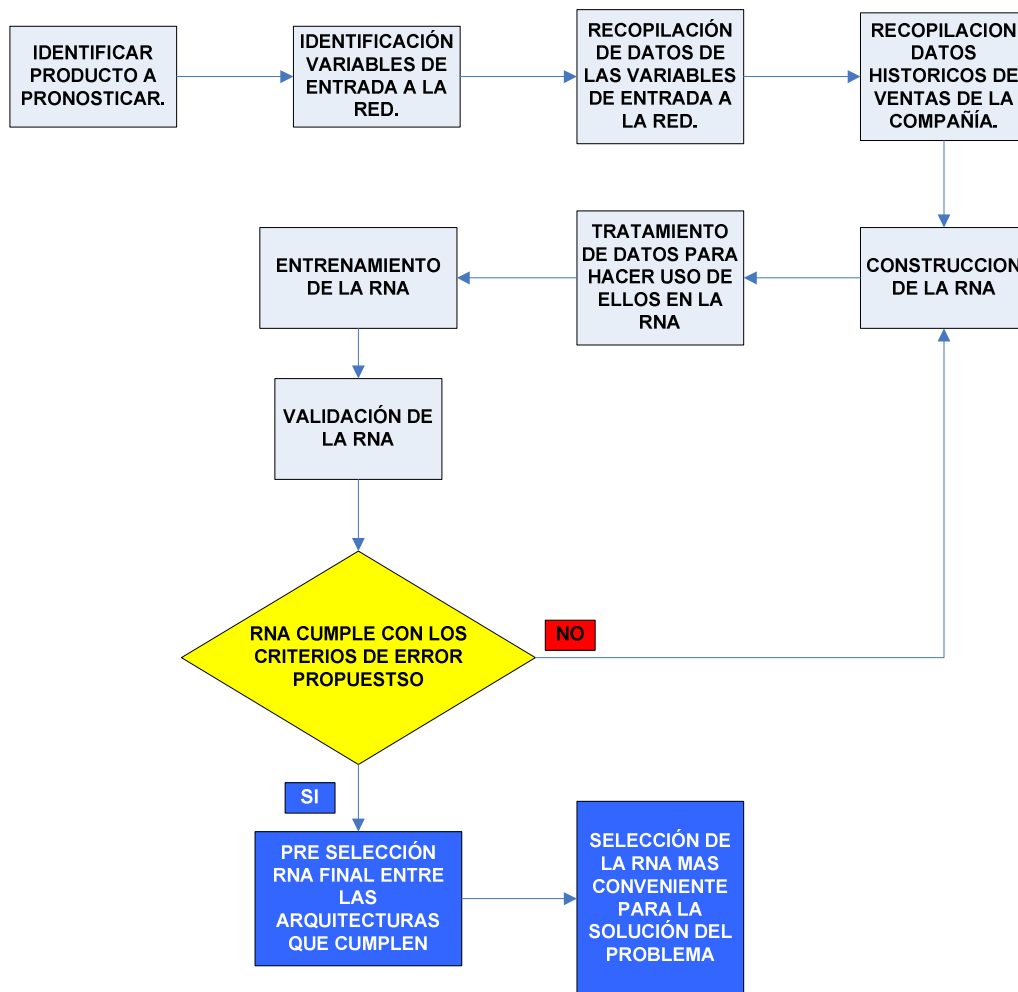


Figura 26. Flujo para la generación de pronóstico con RNA.

3.1.1 Identificación de variables de entrada a la RNA.

Para obtener las variables que tienen una incidencia directa sobre la demanda de los productos seleccionados para el desarrollo de la presente tesis se acude a un grupo de expertos de diferentes áreas como Mercadeo, Ventas y Operaciones, con de una encuesta con variables sugeridas y la posibilidad que desde su experticia sugieran otras variables que sean cuantificables de alguna manera.

Las encuestas realizadas permiten tanto en el oxígeno medicinal como en el nitrógeno para el sector petrolero identificar algunas de las principales variables que afectan el proceso de la demanda. Estas variables serán nuestras entradas en las RNA.

El resultado de las encuestas arroja los siguientes resultados:

Oxígeno Medicinal: **Ver Anexo A**

Nitrógeno sector Petróleos: **Ver Anexo B**

3.1.2 Recopilación de datos históricos de ventas y entradas de la RNA.

Se logra tener información suficiente a través de en ERP de la compañía, obteniendo ventas mes a mes desde enero de 2009. No es posible obtener información más antigua ya que en este año se hizo cambio de ERP por cambio en los accionistas de la compañía.

Frente al problema planteado se tiene un buen número de datos para el entrenamiento de las RNA y su posterior validación.

Los datos de las entradas se obtienen de entidades gubernamentales como el Ministerio de minas, el IDEAM, investigaciones de mercadeo Cryogas, y cuantificación de la información obtenida en medios de comunicación.

Es importante normalizar todos los datos para una mejor interpretación por parte del software.

En la Tabla 20. Datos históricos de volúmenes de ventas oxígeno líquido medicinal y la Tabla 21. Datos históricos de volúmenes de ventas nitrógeno explotación petrolera se presentan los datos originales y normalizados.

Mes/año	Datos original	Dato normalizado	Mes/año	Datos original	Dato normalizado
Ene-09	656.333	0,73	Ene-10	674.935	0,75
Feb-09	611.721	0,68	Feb-10	634.885	0,70
Mar-09	685.570	0,76	Mar-10	717.320	0,79
Abr-09	664.910	0,74	Abr-10	694.342	0,77
May-09	651.619	0,72	May-10	729.039	0,81
Jun-09	723.777	0,80	Jun-10	729.754	0,81
Jul-09	682.554	0,76	Jul-10	732.022	0,81
Ago-09	692.506	0,77	Ago-10	732.137	0,81
Sep-09	702.973	0,78	Sep-10	753.118	0,83
Oct-09	683.327	0,76	Oct-10	732.921	0,81
Nov-09	692.322	0,77	Nov-10	750.842	0,83
Dic-09	733.223	0,81	Dic-10	765.195	0,85
Mes/año	Datos original	Dato normalizado	Mes/año	Datos original	Dato normalizado
Ene-11	689.641	0,76	Ene-12	768.431	0,85
Feb-11	668.373	0,74	Feb-12	740.601	0,82
Mar-11	761.403	0,84	Mar-12	782.429	0,87
Abr-11	748.129	0,83	Abr-12	821.305	0,91
May-11	833.327	0,92	May-12	827.986	0,92
Jun-11	777.940	0,86	Jun-12	819.851	0,91
Jul-11	755.150	0,84	Jul-12	763.902	0,85
Ago-11	775.695	0,86	Ago-12	760.899	0,84
Sep-11	752.817	0,83	Sep-12	710.788	0,79
Oct-11	687.854	0,76	Oct-12	834.417	0,92
Nov-11	765.518	0,85	Nov-12	778.873	0,86
Dic-11	833.928	0,92	Dic-12	743.164	0,82
Mes/año	Datos original	Dato normalizado	Mes/año	Datos original	Dato normalizado
Ene-13	781.373	0,87			
Feb-13	658.200	0,73			
Mar-13	748.351	0,83			
Abr-13	903.076	1,00			
May-13	827.857	0,92			
Jun-13	759.713	0,84			
Jul-13					
Ago-13					
Sep-13					
Oct-13					
Nov-13					
Dic-13					

Tabla 20. Datos históricos de volúmenes de ventas oxígeno líquido medicinal

Mes/año	Datos original	Dato normalizado	Mes/año	Datos original	Dato normalizado
Ene-09	12.208	0,02	Ene-10	88.484	0,17
Feb-09	214.892	0,41	Feb-10	39.595	0,08
Mar-09	199.910	0,38	Mar-10	56.700	0,11
Abr-09	385.806	0,74	Abr-10	60.254	0,12
May-09	107.258	0,21	May-10	78.655	0,15
Jun-09	63.324	0,12	Jun-10	64.254	0,12
Jul-09	74.922	0,14	Jul-10	70.257	0,14
Ago-09	19.026	0,04	Ago-10	35.279	0,07
Sep-09	232.953	0,45	Sep-10	28.289	0,05
Oct-09	265.067	0,51	Oct-10	55.512	0,11
Nov-09	68.882	0,13	Nov-10	89.991	0,17
Dic-09	519.794	1,00	Dic-10	30.771	0,06
Mes/año	Datos original	Dato normalizado	Mes/año	Datos original	Dato normalizado
Ene-11	321.928	0,62	Ene-12	257.025	0,49
Feb-11	19.793	0,04	Feb-12	89.089	0,17
Mar-11	288.340	0,55	Mar-12	102.026	0,20
Abr-11	-	0,00	Abr-12	145.165	0,28
May-11	174.664	0,34	May-12	350.796	0,67
Jun-11	62.078	0,12	Jun-12	183.546	0,35
Jul-11	231.466	0,45	Jul-12	48.734	0,09
Ago-11	123.255	0,24	Ago-12	64.511	0,12
Sep-11	42.920	0,08	Sep-12	210.361	0,40
Oct-11	131.434	0,25	Oct-12	10.706	0,02
Nov-11	99.359	0,19	Nov-12	67.650	0,13
Dic-11	169.489	0,33	Dic-12	260.720	0,50
Mes/año	Datos original	Dato normalizado	Mes/año	Datos original	Dato normalizado
Ene-13	315.817	0,61			
Feb-13	55.713	0,11			
Mar-13	140.586	0,27			
Abr-13	209.716	0,40			
May-13	233.119	0,45			
Jun-13	192.633	0,37			
Jul-13					
Ago-13					
Sep-13					
Oct-13					
Nov-13					
Dic-13					

Tabla 21. Datos históricos de volúmenes de ventas nitrógeno explotación petrolera

3.1.3 Construcción red neuronal artificial.

3.1.3.1 Definición de entradas y salidas.

Las variables de entrada se obtuvieron bajo el proceso mencionado en el punto 3.1.1 3.1.1 Identificación de variables de entrada a la RNA.

Nuestra salida (y) es la cantidad de producto a vender en periodos mensuales, así la cantidad obtenida es la cantidad a producir en determinado mes más un margen de error para poder cubrir la demanda pronosticada.

Y_x = Cantidad pronosticada de ventas en el mes x .

En el problema se plantea aplicar el pronóstico a dos productos de la compañía Cryogas.

3.1.4 Construcción de la RNA

En el capítulo 2.5.5.1 se concluyó que el tipo de RNA a usar es una red Perceptrón multicapa. A continuación se presenta un esquema gráfico de la arquitectura de la RNA, este tendrá un total de 10 neuronas en la primera capa que corresponden a las variables de entrada, se probaran diferentes cantidades de capas ocultas en las cuales se procesa la información y una capa de salida con una sola neurona que representa el pronóstico esperado.

La RNA posee las siguientes características:

- Tipo de red: Perceptrón multicapa.
- Tipo de aprendizaje: *Backpropagation*
- Numero de capas de la red: mayor o igual a 3 capas, incluidas la capa de entradas, las ocultas y la de salida.
- Numero de neuronas capa de entrada: 10, que corresponden al número de variables de entrada que afectan el problema.
- Numero de capas ocultas: Se determina este número basado en el comportamiento de las pruebas que se presentan en el capítulo 3.1.6.

- Numero de neuronas en las capas ocultas: Se determina este número de neuronas basado en el comportamiento de las pruebas presentadas en el capítulo 3.1.6.
- Numero de capas de salida: 1, basados en las características del problema.
- Numero de neuronas en la capa de salida: 1, basados en las características del problema.

En la figura 27 se representa la arquitectura de la red.

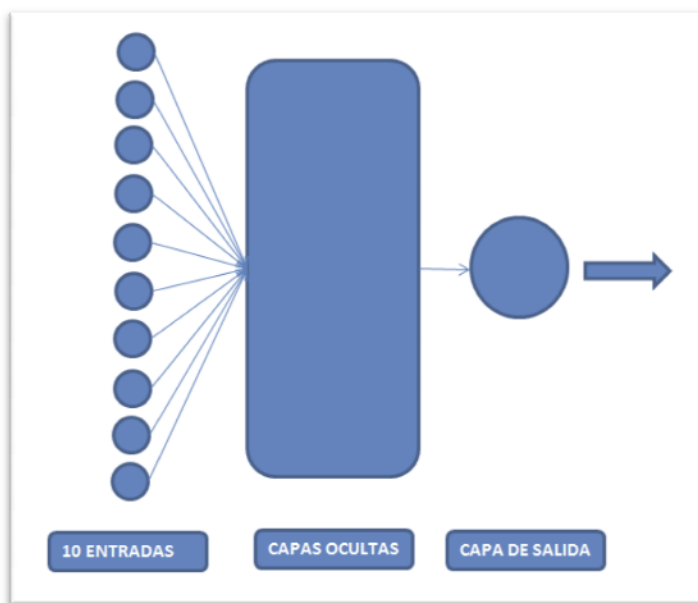


Figura 27 Arquitectura RNA para la LOMX y LINP. Fuente propia.

La metodología usada para la construcción de la RNA consiste en crear diferentes arquitecturas de Perceptrón multicapa en el *Toolbox* de redes neuronales de Matlab®, para luego ser entrenadas y validadas eligiendo la de mejor desempeño medida por el error entre el pronóstico y el dato real.

Código estándar usado:

```
%Código para la creación de RNA para usarse en la tesis de
%grado de Daniel Mauricio Rosas
```

```
%pronosticador 1
```

```

%cargo entradas y salidas
load p.mat%entradas
load q.mat%salidas objetivo
load tiempo.mat%tiempo para la grafica
load rln.mat%entradas incluidas las entradas para validación
load snl.mat%salidas incluidas las de validación para la comparación.
load x2%tiempo para la segunda grafica

%creación de la red
%Se elige Nro. de Capas, numero de neuronas por capa, tipos de funciones
de
%transferencia y algoritmo de entrenamiento.
net=newff(minmax(p), [50,15,5,10,1], {'tansig', 'tansig', 'tansig', 'tansig', '
tansig'}, 'trainlm') %'purelin', 'logsig' otras funciones de transferencia
net.trainParam.show = 50%intervalo de visualización del resultado
net.trainParam.lr = 0.05%rata de aprendizaje
net.trainParam.mc = 0.9%coeficiente de momentun,
net.trainParam.epochs = 10000%nro de repeticiones
net.trainParam.goal = 1e-8%max error permitido esperado
[net,tr]=train(net,p,q)%entrenamiento de la red

```

3.1.5. Tratamiento de los datos para las entradas de la red

Los datos obtenidos para ser usados como las entradas de la red se normalizan para un mejor y más fácil tratamiento por parte del software. VER Anexo E y Anexo F

$$D_i N = \frac{D_i - D_{\min}}{D_{\max} - D_{\min}}$$

$D_i N$ = Dato i Normalizado

D_i =Dato i

D_{\max} = Dato con valor Máximo de la variable.

Para todos los datos i.

3.1.6 Entrenamiento de la RNA y validación de resultados.

Se hace uso de los datos obtenidos como entradas de la red tanto de Cryogas como de fuentes externas para generar la fase de entrenamiento. Se toma los periodos de los años 2009, 2010, 2011, 2012 y primer semestre de 2013, para la etapa de entrenamiento. En los casos con que no se cuenta con suficiente información hace uso de varias fuentes de información como expertos en los procesos, para no dejar una variable sin influencia sobre el entrenamiento.

El objetivo de esta etapa es que la red neuronal pueda asociar los diferentes valores de las variables de entrada con los valores que se van obteniendo a la salida de la red, así la red neuronal puede aprender a pronosticar de la manera más exacta la demanda futura de cada uno de los productos de estudio, haciendo los ajustes necesarios en los pesos que son el reflejo del conocimiento almacenado. Una vez se tengan las RNA validadas, se procede a realizar 3 pronósticos con cada RNA para comparar los resultados pronosticados con los datos reales del tercer trimestre de 2013 y cuantificar el error porcentualmente.

Para este proceso se hace uso del Toolbox NN que hace parte del Software MATLAB®, con el cual se realizaron varios diseños de redes y configuraciones para poder realizar una comparación cuantitativa desde el punto de vista del error y elegir la mejor según sea el producto que se está tratando.

Pronosticadores LINP

Se hace en todos los casos uso del algoritmo de *entrenamiento Levenberg-Maquardt* y criterio de determinación del error *Mean Squared error*

En todos los casos se realizan 3 predicciones con la misma RNA, no se hace ajuste de pesos para los pronósticos 2 y 3 para determinar el desempeño a un periodo superior a un mes.

Variable	Unidad	Valor	Variable	Unidad	Valor	Variable	Unidad	Valor	Variable	Unidad	Valor	Variable	Unidad	Valor	Variable	Unidad	Valor	Variable	Unidad	Valor	
1	1	1	Variable	1	Variable	1	Variable	1	Variable	1	Variable	1	Variable	1	Variable	1	Variable	1	Variable	1	Variable
2	2	2	Variable	2	Variable	2	Variable	2	Variable	2	Variable	2	Variable	2	Variable	2	Variable	2	Variable	2	Variable
3	3	3	Variable	3	Variable	3	Variable	3	Variable	3	Variable	3	Variable	3	Variable	3	Variable	3	Variable	3	Variable
4	4	4	Variable	4	Variable	4	Variable	4	Variable	4	Variable	4	Variable	4	Variable	4	Variable	4	Variable	4	Variable

Tabla 22 Tabla comparativa pronosticadores de LINP.




Figura 28 Respuesta de la RNA vs datos originales




Figura 29 Validación de datos, dato pronosticado vs dato real pronosticador 1.




Figura 30 Validación de datos, dato pronosticado vs dato real pronosticador 2.




Figura 31 Validación de datos, dato pronosticado vs dato real pronosticador 3.

Tomando los dos primeros pronósticos el mejor desempeño para el caso del LINP lo obtuvo el pronosticador número 2.

Descripción	Pronosticador 1	Pronosticador 2	Pronosticador 3
...
...
...
...	273.021	209.149	22.696
...
...
...

Tabla 24 Comparativo pronósticos RNA vs Pronostico Cryogas y volúmenes reales.

Se evidencia la diferencia entre el método actual de pronóstico y el método sugerido a través del uso de redes neuronales, es este último significativamente mejor, obteniendo desviaciones hasta del 12%, mientras que en el método actual se presentan desviaciones hasta del 46%. Las desviaciones de septiembre de 2013 no se tienen en cuenta por el daño de planta presentado durante este mes.

Pronosticadores LOXM

Se hace en todos los casos uso del algoritmo de entrenamiento *Levenberg-Maquardt* y criterio de determinación del error *Mean Squared error*

En todos los casos se realizan 3 predicciones con la misma RNA, no se hace ajuste de pesos para los pronósticos 2 y 3.

Variable	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo	Modelo
1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4

Tabla 25 Tabla comparativa pronosticadores de LOXM.




Figura 33 Validación de datos, dato pronosticado vs dato real pronosticador 1.




Figura 34 Validación de datos, dato pronosticado vs dato real pronosticador 2.




Figura 35 Validación de datos, dato pronosticado vs dato real pronosticador 3.




Figura 36 Validación de datos, dato pronosticado vs dato real pronosticador 4.

Tabla 29	
Descripción del método actual	Resultados
Descripción del método propuesto	Resultados
Conclusión	Resultados

Tabla 29 Comparación método actual y propuesto LINP

Esta tesis genera las bases necesarias para realizar pronósticos a corto y mediano plazo de los volúmenes a vender en dos segmentos comerciales y de aplicaciones totalmente diferentes y de comportamiento irregular, con resultados más exactos y consistentes que los actuales, que pueden ser usados para la producción de las plantas ASU de Cryogas y obtener como resultado a través de la buena planeación, un menor costo unitario de producción mejorando la eficiencia energética y el correcto balance de almacenamiento evitando arranques y paradas de planta no planeados que afectan negativamente los costos de producción.

Cryogas puede mejorar su eficiencia energética en la producción en sus plantas ASU mediante la aplicación del método de pronóstico de la demanda con redes neuronales planteado en la presente tesis y los resultados obtenidos, logrando llegar disminuir el indicador de eficiencia hasta en un 4% en la planta de Barbosa y un 22% en la planta de Sibate.

Por último es necesario resaltar que la demanda es dinámica y que las variables identificadas en la actualidad pueden cambiar o ajustarse según sea el comportamiento de los mercados, se deben generar ajustes de pesos periódicamente en las arquitecturas de las RNA y validar los resultados con el equipo de ventas para evitar omitir información puntual y relevante que modifica los hábitos de consumo de los clientes.

Bibliografía

- Armstrong, J. S., & Green, K. C. (2006). Demand Forecasting—Evidence-based Methods A chapter for the forthcoming book Strategic Marketing Management—A Business Process Approach , edited by Luiz Moutinho and Geoff Southern . J . Scott Armstrong The Wharton School , University of Pennsylvania, 1–17.
- Cintado, L. (2009). PREVISION DE LA PRODUCCION EN EL CENTRO DE ELABORACION, 2009.
- Claveria, P., Lozano, M., & Hombrados, A. (2001). Modelizacion y simulación de plantas criogenicas de separacion de aire con hysys, (1).
- Curtis, A., Persson, P. L., & Shore, K. A. (2003). Recent Advances in Multidisciplinary Applied Physics.
- GAITHER, N., & FRAIZER, G. (2000). Administracion de Produccion y Operaciones.
- http://softwarelibre.unsa.edu.ar/docs/descarga/2003/curso/htmls/redes_neuronales/x185.html. (2003)
- http://www.disa.bi.ehu.es/spanish/profesores-etsi-bilbo/~jtpcaaxi/PFC/wwwANN/arquitectura_archivos/image012.gif. (2013).
- Iranmanesh, H., Abdollahzade, M., & Miranian, A. (2011). Mid-term energy demand forecasting by hybrid neuro-fuzzy models. *Energies*, (Mi), 1–21. doi:10.3390/en5010001
- Martín, B., & Sanz, A. (1997). Redes neuronales y sistemas borrosos. *Zaragoza: Editorial Ra-Ma*, 404.
- Moreno, J. (2002). Redes neuronales artificiales aplicadas al análisis de datos. *Palma de Mallorca*.

Render, B. (2004). *Principios de administración de operaciones*.

Salazar, M., & Cabrera-Ríos, M. (2007). Pronóstico de demanda por medio de redes neuronales artificiales. *Ingenierías*, X, X(35), 6–12.

SIERRA GUERRERO, A. M. (2013). PRONOSTICO DE LA DEMANDA.

Sierra, M. (2007). Inteligencia artificial en la gestión financiera empresarial. *Pensamiento & Gestión*.

Sipper, D., & Bulfin, R. (1998). *PLANEACION Y CONTROL DE LA PRODUCCION*. Mc Graw Hill.

ANEXOS

ANEXO A: Variables entradas RNA LOXM

Categoría	Subcategoría	Variable	Unidad	Fuente
A	B	C1	D1	E1
		C2	D2	E2
		C3	D3	E3
		C4	D4	E4
		C5	D5	E5
		C6	D6	E6
		C7	D7	E7
		C8	D8	E8
		C9	D9	E9
		C10	D10	E10
		C11	D11	E11
		C12	D12	E12
A	B	<p>C1 C2 C3 C4 C5 C6 C7 C8 C9 C10 C11 C12</p>	D	<p>E1 E2</p> <hr/> <p>E3 E4</p>

ANEXO B: Variables entradas RNA LINP

Variable	Código	Descripción	Unidad	Fuente
Variable 1	Código 1	Descripción 1	Unidad 1	Fuente 1
Variable 2	Código 2	Descripción 2	Unidad 2	Fuente 2
Variable 3	Código 3	Descripción 3	Unidad 3	Fuente 3
Variable 4	Código 4	Descripción 4	Unidad 4	Fuente 4

???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	???	???	???	??	??	??	???	???	??
???	???	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	??	???	???	??	??	??	???	???	??
???	???	???	???	??	??	??	???	???	??
???	???	???	???	??	??	??	???	???	??
???	???	???	???	??	??	??	???	???	??

