



**Universidad Nacional Mayor de San Marcos**  
Universidad del Perú. Decana de América  
Facultad de Ingeniería de Sistemas e Informática  
Escuela Académica Profesional de Ingeniería de Sistemas

**Implementación de una Red Neuronal para mejorar el  
pronóstico de la demanda de energía en la empresa  
BlueStar Energy Services Inc.**

**TESINA**

Para optar el Título Profesional de Ingeniero de Sistemas

**AUTORES**

Ronny Ronald CUADRADO MONTALVO

Judith Carolina RAMOS VALDEZ

**ASESOR**

Luis Antonio RIVERA ESCRIBA

Lima, Perú

2010



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

## Referencia bibliográfica

---

Cuadrado, R & Ramos, J. (2010). *Implementación de una Red Neuronal para mejorar el pronóstico de la demanda de energía en la empresa BlueStar Energy Services Inc.* Tesina para optar el título profesional de Ingeniero de Sistemas. Escuela Académica Profesional de Ingeniería de Sistemas, Facultad de Ingeniería de Sistemas e Informática, Universidad Nacional Mayor de San Marcos, Lima, Perú.

---

## DEDICATORIA

*A nuestros padres, por su apoyo,  
Comprensión y consejos.*

## AGRADECIMIENTOS

A los colegas de la empresa BlueStar Energy Services Inc., Por su apoyo en la realización de este trabajo.

A todas las personas que indirectamente nos ayudaron a culminar este trabajo y que constituyeron un invaluable apoyo.

# ÍNDICE

	Pág.
<b>CAPÍTULO I: PROBLEMÁTICA DE PRONÓSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA</b>	
1.1. Realidad problemática	2
1.2. Enunciado del problema	5
1.3. Justificación	6
1.4. Alternativa de solución	9
1.5. Objetivos	10
1.5.1. Objetivo general	10
1.5.2. Objetivos específicos	10
1.6. Alcances	11
1.7. Variables e indicadores	12
1.7.1. Variables	12
1.7.2. Indicadores	12
<b>CAPÍTULO II: MARCO REFERENCIAL</b>	
2.1. Pronóstico	16
2.2. Pronóstico de la demanda	18
2.2.1. Horizonte de tiempo	22
2.2.2. Factores que afectan la demanda eléctrica	25
2.2.3. La naturaleza de la demanda de energía eléctrica	27
2.2.4. Influencia del factor temperatura	27
2.2.5. Retos en la predicción de la demanda eléctrica	29
2.2.6. Implicaciones económicas para las empresas eléctricas	30
2.3. Redes neuronales artificiales	32
2.3.1. Definición de las RNA	33
2.3.2. Historia de las RNA	40
2.3.3. Estructura de las RNA	41

2.3.4.	Mecanismos de aprendizaje de las RNA	45
2.3.5.	Topologías de las RNA	46
2.3.6.	Aplicaciones de las RNA	51
2.3.7.	Ventajas y desventajas de las RNA	53
2.3.8.	Cuestiones a resolver al trabajar con una RNA	54
2.4.	Inteligencia artificial	55
2.4.1.	La inteligencia	55
2.4.2.	Inteligencia artificial	56
2.4.3.	Ramas de la inteligencia artificial	57
2.5.	Antecedentes	61
2.6.	Metodologías para la predicción	67
2.6.1.	Lógica Difusa	67
2.6.2.	Redes Neuronales Artificiales	70
2.6.3.	Data Mining	74
2.6.4.	Elección de la Metodología a Utilizar	78
<b>CAPÍTULO III: ARQUITECTURA DE LA RED NEURONAL</b>		
3.1.	Variables que intervienen en la red neuronal	80
3.1.1.	Condiciones meteorológicas	80
3.1.2.	Calendario	81
3.2.	Modelo neuronal de la demanda	84
3.3.	Justificación del tipo de red	87
3.4.	Construcción de la red neuronal	88
3.5.	Implementación de una red neuronal en MATLAB	89
3.6.	Interfaces de usuario de la aplicación	98
<b>CAPÍTULO IV: CONCLUSIONES Y RECOMENDACIONES</b>		
4.1.	Conclusiones	110
4.2.	Recomendaciones	111
<b>BIBLIOGRAFÍA</b>		112

## ÍNDICE DE FIGURAS

	Pág.
<b>Figura 1.1.</b> Nivel de desregulación en EEUU.	4
<b>Figura 2.1.</b> Exceso de Oferta.	19
<b>Figura 2.2.</b> Exceso de Demanda.	19
<b>Figura 2.3.</b> Influencia de las estaciones sobre la demanda eléctrica.	27
<b>Figura 2.4.</b> Modelo de trabajo con Redes Neuronales.	35
<b>Figura 2.5.</b> Representación de una Neurona Artificial.	36
<b>Figura 2.6.</b> Función lineal.	37
<b>Figura 2.7.</b> Función escalón.	38
<b>Figura 2.8.</b> Función tangencial.	39
<b>Figura 2.9.</b> Niveles de la neurona.	42
<b>Figura 2.10.</b> Conexión entre neuronas – Todos con todos.	43
<b>Figura 2.11.</b> Conexión entre neuronas – Unión lineal.	44
<b>Figura 2.12.</b> Conexión entre neuronas – Predeterminado.	44
<b>Figura 2.13.</b> Arquitectura del Perceptrón Monocapa.	48
<b>Figura 2.14.</b> Arquitectura del Perceptrón Multicapa.	51
<b>Figura 2.15.</b> Ramas de la Inteligencia Artificial.	57
<b>Figura 2.16.</b> Mecanismo de un Sistema Experto.	58
<b>Figura 2.17.</b> Ejemplo de sistema de lenguaje natural.	59
<b>Figura 3.1.</b> Curva de la demanda.	81
<b>Figura 3.2.</b> Curvas de la demanda según los días de la semana.	82
<b>Figura 3.3.</b> Curva de la demanda a lo largo de la semana.	83
<b>Figura 3.4.</b> Curva de la demanda anual.	84
<b>Figura 3.5.</b> Representación esquemática de la RNA empleada.	85
<b>Figura 3.6.</b> Representación de la comunicación entre las tecnologías.	89
<b>Figura 3.7.</b> Matriz en MATLAB.	92

<b>Figura 3.8.</b> Vector con entradas.	93
<b>Figura 3.9.</b> Creación de red neuronal.	94
<b>Figura 3.10.</b> Entrenamiento de la red.	95
<b>Figura 3.11.</b> Resultados del entrenamiento.	96
<b>Figura 3.12.</b> Resultados.	97
<b>Figura 3.13.</b> Página de inicio.	99
<b>Figura 3.14.</b> Login.	100
<b>Figura 3.15.</b> Menú.	101
<b>Figura 3.16.</b> Elección de fechas.	102
<b>Figura 3.17.</b> Predicción para el día siguiente.	103
<b>Figura 3.18.</b> Predicción para la semana siguiente.	105
<b>Figura 3.19.</b> Predicción para un rango determinado.	107

## ÍNDICE DE TABLAS

	Pág.
<b>Tabla 1.1.</b> Variables e indicadores	10
<b>Tabla 3.1.</b> Datos de entrada	86

# **Implementación de una Red Neuronal para mejorar el pronóstico de la demanda de energía:**

## **Caso Empresa BlueStar**

ASESOR: Luis Antonio Rivera Escriba

### **RESUMEN**

El objetivo de este trabajo es lograr predecir la demanda de electricidad en la empresa BlueStar Energy Services Inc. con la mayor precisión posible, para poder disminuir las pérdidas que producen el sobre abastecimiento de electricidad, así como la falta de abastecimiento. Cuando la empresa se sobre abastece de energía que no logra vender, tiene pérdidas debido a que la energía eléctrica no puede almacenarse para poder ser vendida con posterioridad. En caso contrario si se produce una falta de abastecimiento, esto traería graves consecuencias para la empresa puesto que no podría satisfacer la demanda de energía eléctrica hecha por sus clientes, y con el fin de subsanar estos inconvenientes tendría que comprar la energía eléctrica a un precio mayor lo cual también acarrearía pérdidas para la empresa.

La metodología propuesta para lograr predecir con mayor exactitud la demanda de energía eléctrica es la construcción de una red neuronal, tomando en cuenta factores que afectan el consumo de electricidad, logrando así un mejor pronóstico, que con los modelos de predicción tradicionales. Para esto hemos considerado diversos factores que influyen en el consumo de electricidad por parte de los clientes de la empresa, siendo los factores meteorológicos uno de los más importantes. Asimismo siendo el uso de las redes neuronales un medio de predicción que ha dado importantes resultados en diferentes

investigaciones, podría aplicarse también para la predicción de la demanda de energía eléctrica en la empresa BlueStar.

Los resultados muestran que a través del uso de redes neuronales, se logró una mejor aproximación de la demanda futura. Entonces podemos concluir que las redes neuronales artificiales son más eficientes en la predicción frente a escenarios desconocidos.

Palabras clave: Red neuronal artificial, predicción, consumo de electricidad, IA.

# **Implementation of a Neural Network to improve forecasting of energy demand:**

## **BlueStar Company Case**

ASSESSOR: Luis Antonio Rivera Escriba

### **ABSTRACT**

The aim of this work is to predict demand in the company BlueStar Energy Services Inc. as accurately as possible in order to reduce losses that occur when exist an oversupply of electricity and lack of electricity supply. When the company has an oversupply of electricity, have losses because electricity can not be stored to be sold later. Otherwise, if there is a lack of electricity supply, this would have severe consequences for the company because could not meet electricity demand made by their customers, and in order to remedy these problems, the company would have to buy electricity at a higher price and this also means greater losses for the company.

The proposed methodology for achieving more accurately predict is the building of a neural network, taking into account factors that affect electricity consumption, thus achieving a better outcome than with traditional forecasting models. For that, we have considered various factors that influence the consumption of electricity by customers of the company, taking the meteorological factors one of the most important. Also, considering the use of neural networks as a means of prediction that has yielded important results in various investigations could be applied for predicting electric demand in BlueStar.

The results show that through the use of neural networks a better approximation of future demand was achieved. Then we can conclude that artificial neural networks are more efficient in forecast for unknown scenarios.

Keywords: Artificial neural network, prediction, electricity consumption, IA.

## INTRODUCCIÓN

El objetivo de nuestra investigación es predecir la demanda eléctrica a futuro utilizando redes neuronales para la empresa BlueStar Energy Services Inc. con sede en EEUU, con el fin de que pueda obtener mayores ganancias y mantener a sus clientes satisfechos con el servicio que se les brinda.

La energía eléctrica se ha convertido en un bien indispensable y de gran interés estratégico para la economía de los países avanzados. Por esta razón las compañías eléctricas deben adecuar la producción a la demanda para garantizar a sus clientes la calidad de servicio contratada a un precio competitivo. Para conseguir este objetivo es necesario predecir la demanda de energía con antelación suficiente para poder planificar la producción. Una predicción inferior al consumo hará que el proveedor deba comprar en energía en el mercado nacional intradiario o que deba generar la energía faltante por medios más caros de los que se hubiera utilizado con una predicción correcta. Esto supondrá pérdidas económicas tanto para la empresa como para sus clientes. Además, si el resto de compañías han subestimado la demanda se pueden incluso producir cortes en el suministro con pérdidas económicas importantes. Por otro lado, sobreestimar la demanda implica que es necesario vender la energía sobrante en el mercado intradiario a un precio inferior al deseado perdiendo dinero. Por tanto, es muy importante predecir la demanda de energía futura con el menor error posible.

Para poder predecir la demanda eléctrica a futuro decidimos utilizar redes neuronales puesto que operan sobre la base de reconocimiento de patrones, y pueden adquirir, almacenar y utilizar conocimiento experimental, obtenido a partir de ejemplos. Las RNA constituyen un potente instrumento para la aproximación de funciones no lineales. Su uso resulta especialmente útil en la modelización de aquellos fenómenos complejos donde la presencia de

relaciones no lineales entre las variables es habitual, y por tanto puede aplicarse a nuestra investigación.

La aplicación de las redes neuronales en diferentes áreas ha proporcionado interesantes resultados, siendo el campo de las predicciones donde ha conseguido ser utilizada con mucha efectividad. Por ejemplo se han realizado investigaciones para pronosticar el precio del cobre utilizando redes neuronales, concluyendo que éstas son una herramienta más efectiva que las que se utilizan de manera común. Igualmente las redes neuronales se han aplicado para pronosticar ventas en las empresas comerciales con el fin de lograr obtener mayores utilidades que las obtenidas con medios más usuales.

Para elaborar nuestra red neuronal hemos utilizado el software MATLAB, puesto que nos permite construir nuestra red de una manera sencilla, y haciendo uso de la librería jMatLink, podemos lograr la interacción entre una aplicación java (en nuestro caso J2EE) con una instancia de MATLAB.

Hemos empezado nuestro trabajo de investigación definiendo en el primer capítulo el problema, la realidad problemática, los objetivos, los antecedentes. En el segundo capítulo explicamos nuestro marco referencial. En el tercer capítulo establecemos cuál será nuestra arquitectura de red neuronal. En el cuarto capítulo presentamos nuestras conclusiones y recomendaciones.

**CAPÍTULO I:**  
PROBLEMÁTICA DE PRONÓSTICO DE  
CONSUMO DE ENERGÍA ELÉCTRICA

La previsión de la demanda de cualquier producto o servicio intenta revelar las necesidades futuras de una población. Esta previsión debe ser lo más ajustada a la realidad, ya que unos valores inferiores a los reales causarían deficiencias en la prestación del servicio en el futuro, y un pronóstico de necesidades superior al real motiva la inversión prematura en instalaciones que no tendrán un aprovechamiento inmediato.

Por ende la mayoría de empresas de distribución eléctrica en diversos países buscan obtener un pronóstico de la demanda de energía con el menor margen de error con el fin de aumentar sus ganancias y mantener satisfechos a sus usuarios.

## **1.1 Realidad problemática**

El sistema regulatorio de los EEUU, para industrias de redes con tendencias monopólicas (electricidad, telefonía, transporte terrestre, aerolíneas) estuvo bajo la jurisdicción de comisiones estatales, para asegurar que el desarrollo fuera transparente.

Para el caso de la electricidad, se establecieron bases para la electrificación de todo el país, el crecimiento industrial, las tarifas bajas y la implementación de protecciones sociales para los consumidores.

En los años recientes, los economistas y analistas políticos han alentado las ventajas de la competencia, sobre los sistemas monopólicos regulados; y han promovido la idea de que los mercados libres pueden provocar una baja en los costos y precios, además de reducir ineficiencias y estimular innovaciones tecnológicas.

Es así que los legisladores y reguladores están instituyendo leyes y reglas que promueven la competencia, ya que se cree que los consumidores se beneficiarán más de una industria en la que los

miembros deban competir por los clientes, que de una industria integrada por monopolios regulados.

El empuje principal viene de los usuarios industriales de electricidad, que en algunas áreas de EEUU se ven afectados por los altos precios de electricidad, comparados con otras áreas de EEUU donde el precio de kilowatt/hora es mucho menor.

Estos clientes industriales, ya que son grandes consumidores de electricidad; al tener la oportunidad de elegir un abastecedor a menor precio, lograrían grandes reducciones en sus costos.

Otro factor que ha influido en la reestructuración de esta industria, son los avances tecnológicos para la producción de electricidad. Esto ha permitido a los nonutilities (entidades de propiedad privada que generan la energía para su propio uso y/o para la venta a los utilities y a otros) usar avances recientes y generar electricidad a menor costo que muchas utilities (Compañías privadas o agencias públicas comprometidas en la generación, transmisión, y/o distribución de energía eléctrica de uso público), que actualmente usan tecnologías de combustible fósil u otros.

Este proceso de Desregulación aún no ha sido adoptado por todos los estados de EEUU; como se puede observar en la figura 1.1, solo en algunos estados se viene dando la desregulación, mientras que en otros todavía no se da esta tendencia.



mayorista y lo revende a los clientes, tratando de ofrecer un mejor precio que los utilities locales como ComEd (Commonwealth Edison Co.) y Ameren Corp.

Esto lo logra comprando energía diariamente con la esperanza de obtener las tarifas más bajas. Por el contrario, los utilities, adquieren la mayoría de su energía una vez al año, independientemente de su precio.

En función del mercado y los patrones de uso de la electricidad, una empresa puede ahorrar nada o puede reducir su factura hasta un 50% con BlueStar. En promedio, el ahorro de los clientes es de 5% a 13%.

## **1.2 Enunciado del problema**

Actualmente el cálculo realizado para la predicción futura del consumo de electricidad de los clientes de BlueStar, se viene dando a través de cálculos estadísticos avanzados, que implican una gran complejidad en su manejo y adaptación de nuevas variables que pudieran afectar el consumo de electricidad.

Debido a que el consumo de electricidad, es afectado por diferentes tipos de variables (como son: la humedad, el día del año, el clima, etc...), para un acertado pronóstico de la demanda, es necesario usar una metodología multidimensional; es decir, una metodología que soporte múltiples variables que influyen directa o indirectamente en el problema.

En caso de no acertar con el menor margen posible de error, la empresa sufre pérdidas, ya que se puede sobre abastecer de energía innecesaria, o agotar su energía y tener que comprar a un precio mayor la energía faltante.

Es por ello que la empresa busca métodos más exactos para el pronóstico de energía que logren reducir el margen de error que pudiera ocurrir.

### **1.3 Justificación**

Para muchas empresas eléctricas es importante realizar pronósticos de ciertas variables, ya que requieren minimizar la incertidumbre de demanda que se tendrá durante cierto horizonte de tiempo según se desee (corto, mediano o largo plazo).

La previsión de la demanda es una actividad esencial de los suministradores de energía eléctrica. Sin una adecuada representación de las necesidades futuras de generación eléctrica, los problemas de exceso de capacidad, o por el contrario de capacidad insuficiente, pueden tener costes sorprendentemente altos. La correcta previsión de la demanda también desempeña un importante papel en las decisiones de una compañía eléctrica respecto a qué cantidad, y en qué época, será conveniente comprar (vender) energía a otras empresas del sector.

La demanda de la energía eléctrica es un indicador del grado de desarrollo de un país, la cual está en función de: Crecimiento de la población, el parque industrial, agrícola y sector turístico, etc. Por esto es de vital importancia conocer a priori el crecimiento de la demanda de energía eléctrica; de una manera segura y confiable lo cual se aproxime lo más cercano a la realidad. Para esto se requiere de técnicas apropiadas para realizar un buen pronóstico a corto, mediano y largo plazo de la demanda; ya que de esto depende garantizar el suministro de energía eléctrica.

El objetivo principal de cualquier compañía de electricidad regulada, es proporcionar electricidad a los consumidores, con un precio razonable. Este objetivo requiere de un buen pronóstico de la demanda de energía eléctrica, sin embargo esto no es fácil ya que las necesidades del ser humano provocan patrones de consumo de energía eléctrica que se describen de diferentes formas.

Por ejemplo en una casa habitación de la ciudad se necesita de un acondicionador de aire, que consumirá una cierta cantidad de electricidad en cierto tiempo; este uso de energía se emplea en el deseo de un individuo para refrescarse, o viceversa en época de frío se necesita de un calentador lo cual ocasionará un consumo de energía eléctrica. Así como este ejemplo la curva característica de la demanda se basa en un sinnúmero de variables de todo tipo. Así pues la gran variedad de consumidores y los diferentes tipos de usos finales de energía eléctrica crean una gran variedad de demandas distintas entre sí.

Con todo este tipo de consumidores, y la gran cantidad de variables que en cierto tiempo determinado influyen directa o indirectamente en la demanda de energía eléctrica, se busca realizar el pronóstico de la demanda con un mínimo de errores aceptables. Aun cuando las personas encargadas de la planeación de la operación y el crecimiento del sistema, están conscientes de la necesidad de mejorar los pronósticos, pocos están al tanto de las técnicas existentes para lograr un buen pronóstico de demanda de energía eléctrica.

Como casi siempre hay un retraso entre el suceso y su previsión, al lograr identificar las causas o factores que influyen para su realización es cuando la planeación juega un papel importante; en este caso el pronóstico es una ayuda indispensable en la planeación efectiva y eficiente.

La importancia del pronóstico de demanda de energía eléctrica se incrementa a medida de las decisiones tomadas, para lograr un objetivo

fijado dependan lo menos posible del azar. Las interconexiones de áreas eléctricas han dado lugar a grandes sistemas eléctricos y como cada área depende de las demás, un buen o mal estudio de pronóstico de demanda de energía eléctrica puede afectar a todo el sistema interconectado.

El problema de pronóstico de demanda de energía eléctrica surge en la necesidad de conocer, en forma aproximada, los valores de una cierta variable o índice, para con este valor tomar las medidas necesarias. Los valores estimados se determinan tomando información “archivo histórico” y procesando adecuadamente los datos, determinando así los patrones o funciones de comportamiento para proyectarlos a futuro.

Un argumento importante a tener en cuenta es el económico. De acuerdo a William Labys (1999) “Si las predicciones resultan ser demasiado bajas pueden tener lugar carencias de energía cuyos costes habitualmente son mucho mayores que el valor de la energía no suministrada. Por el contrario, si las previsiones resultan demasiado altas, los costes de oportunidad pueden ser muy elevados al tener comprometidos, de forma improductiva, cuantiosos fondos económicos durante largos periodos de tiempo”.

La implementación de una red neuronal en el área comercial de la empresa BlueStar Energy Services Inc., tiene por objetivo mejorar el pronóstico de la demanda de energía.

Esta información es conveniente para la empresa, ya que la empresa se dedica a la compra de electricidad de los principales proveedores de electricidad de EEUU como Ameren y Comed, para poder ofrecer este servicio a clientes minoristas (residenciales) en los estados Illinois, Maryland y el distrito de Columbia.

El poder pronosticar con mayor exactitud la demanda, permite la compra de energía más exacta, disminuyendo la compra de energía sobrante y

satisfaciendo completamente a la demanda existente, generando menos pérdidas financieras y más ganancias.

#### **1.4 Alternativa de solución**

La alternativa de solución propuesta para el presente trabajo, es el desarrollo de una red neuronal artificial (rna), la cual será entrenada a partir de data histórica del consumo de electricidad, dando como resultado una modelo del comportamiento de la demanda.

El tipo de red neuronal a utilizar es la red perceptrón multicapas. La ventaja de esta red es que puede aproximar cualquier función si se escoge una configuración y un número adecuado de neuronas en las capas ocultas.

El algoritmo a utilizar en este trabajo es el algoritmo BackPropagation, el cual tiene un aprendizaje supervisado, que necesita conocer cual es la salida esperada asociada a cada una de las entradas, para poder actualizar los pesos y las ganancias. El algoritmo consiste en minimizar un error (comúnmente cuadrático) por medio de gradiente descendiente, por lo que la parte esencial del algoritmo es el cálculo de las derivadas parciales de dicho error con respecto a los parámetros de la red neuronal. El algoritmo es sólo válido para redes tipo feedforward y recibe este nombre por la dirección en que se propaga el error en la red. El ajuste de los pesos mediante este algoritmo se lleva a cabo iterativamente, añadiendo un incremento en cada iteración a dichos pesos. La modificación de los pesos se lleva a cabo considerando que se trata de un problema de minimización del error.

Las variables de entrada elegidas, para la creación del modelo de red neuronal, fueron los factores más importantes que afectan el consumo eléctrico:

- Temperatura: El cambio de temperatura afecta el consumo de electricidad.
- Humedad: Afecta el uso de aparatos eléctricos como aire acondicionado.
- Hora del día: La demanda eléctrica varía de acuerdo a la hora del día.
- Día de la semana: La demanda eléctrica puede variar de acuerdo al día de la semana.
- Fin de semana y feriados: En los fines de semana y los días feriados, se produce una variación en el consumo eléctrico.
- Mes del año: Refleja la variación estacional del consumo de electricidad a causa de los cambios del clima en el año.

## **1.5 Objetivos**

### **1.5.1 Objetivo general**

Implementar una red neuronal para mejorar el pronóstico de la demanda de energía eléctrica en la empresa BlueStar Energy Services Inc.

### **1.5.2 Objetivos específicos**

- Estudiar las diferentes metodologías existentes para el desarrollo de redes neuronales.
- Elegir la mejor metodología.
- Determinar las variables de entrada de la red neuronal.

- Usar simuladores de redes neuronales para poder construir el modelo con menor índice de error, de acuerdo a nuestros datos de entrada y resultados esperados.
- Demostrar que a través del modelo obtenido, se logra un mejor resultado en el pronóstico de la demanda.
- Demostrar que nos encontramos capacitados para desempeñarnos como ingenieros de sistemas.

## **1.6 Alcances**

En el presente trabajo se brinda una solución práctica al problema de la predicción de la demanda eléctrica. Con la aplicación de las Redes Neuronales Artificiales, se resuelve el problema de la complejidad de los modelos de predicción tradicionales, a partir de los factores que realmente afectan el consumo energético. Con el software desarrollado se realiza la predicción del consumo energético de una zona con un error de predicción aceptable.

Con el presente documento pretendemos explorar la capacidad de las Redes Neuronales Artificiales como instrumento de modelización y predicción económica, poniendo de relieve la superioridad mostrada por las mismas en el modelado de los fenómenos no-lineales. Para ello confeccionaremos un modelo neuronal que, implementado en MATLAB, nos permitirá predecir la evolución de la demanda horaria de energía eléctrica.

## 1.7 Variables e indicadores

### 1.7.1 Variables

#### Variable independiente

Red neuronal

#### Variable dependiente

Pronóstico de la demanda de energía en la empresa BlueStar Energy Services Inc.

VARIABLES	INDICADORES	UNIDAD DE MEDIDA
<b>Independiente:</b> Red neuronal.	Presencia – ausencia.	
<b>Dependiente:</b> Pronóstico de la demanda de energía en la empresa BlueStar Energy Services Inc.	Ingresos	\$
	Egresos	\$
	Energía sobrante	Kw.
	Energía faltante	Kw.
	Tiempo de pronóstico	s
	Exactitud	%

Tabla 1.1. Variables e indicadores.

### 1.7.2 Indicadores

Conceptualización de los indicadores

**Ingresos**

Se refiere a la *cantidad* de ingresos financieros (ganancia) que obtiene la empresa, en la unidad monetaria de Dólares (\$).

**Egresos**

Se refiere a la *cantidad* de egresos financieros (perdida) que obtiene la empresa, en la unidad monetaria de Dólares (\$).

**Energía sobrante**

Se refiere a la *cantidad* de energía que la empresa compró, y que no logró ser vendida (distribuida) debido a un sobre abastecimiento de electricidad, medida en Kilo watts (Kw.).

**Energía faltante**

Se refiere a la *cantidad* de energía que la empresa no logró abastecer, debido a que no se contó con la suficiente cantidad de energía para abastecer a todo el mercado, medida en Kilo watts (Kw.).

**Tiempo de pronóstico**

Se refiere a la *cantidad* de tiempo en segundos(s) que tomó el cálculo del pronóstico; desde el ingreso de la información necesaria, hasta el reporte final con los resultados de la predicción.

**Exactitud**

Se refiere al *porcentaje* de que tan cerca del valor real se encuentran los resultados obtenidos. Se expresa mediante el error absoluto, que es la diferencia entre el valor obtenido y el valor real. (%)

## **CAPÍTULO II: MARCO REFERENCIAL**

Los países industrializados han experimentado un crecimiento importante de la demanda eléctrica total en la última década. A medida que crecen las necesidades de suministro eléctrico la complejidad del sistema crece y son muchos los factores que finalmente influyen en la generación y consumo de energía. En este escenario los procesos, técnicas y modelos de predicción requeridos son cada vez más complejos y necesitan de una mayor precisión. Las empresas suministradoras y las generadoras han de realizar estimaciones de la demanda prevista tanto en el corto plazo (en rangos desde unos pocos minutos u horas a varios días de antelación) como en el medio y largo plazo, para la programación de los recursos y la planificación de inversiones.

Sin embargo, la relación entre la demanda y los diferentes factores exógenos es compleja y no-lineal, lo cual hace difícil definir un modelo mediante la utilización de técnicas convencionales, como pueden ser las series temporales o análisis de regresión lineal.

Es por esto que la industria eléctrica se encuentra en una continua búsqueda por mejorar su eficiencia en el suministro de energía eléctrica y dado el actual sistema competitivo (desregulados) está investigando nuevas tecnologías que la puedan asistir y brindar resultados adecuados para realizar una adecuada predicción.

Esta tendencia general ha llevado a que varias tecnologías de la inteligencia artificial (IA) como sistemas expertos, redes neuronales artificiales, lógica difusa y algoritmos genéticos sean aplicadas al menos como prototipos en la industria eléctrica. La ventaja de estas nuevas técnicas de simulación es que permiten el tratamiento de datos históricos como información base en el proceso de simulación, aunque se desconozca exactamente la dinámica interna del proceso pues presentan la particularidad de aprender a partir de ejemplos reales y permitir la predicción de comportamientos a partir de una serie de valores de entrada.

## 2.1 Pronóstico

Cuando hablamos acerca de algún pronóstico, significa que se ha establecido un enunciado claro sobre algo que es probable que suceda en el futuro, basándose en análisis y consideraciones de juicio. Medir esa probabilidad nos lleva directamente a consideraciones cuantitativas, que se consideran terreno propio de las matemáticas.

Al hacer un pronóstico, nuestra atención se centra en establecer lo que de alguna manera totalmente determinística se prevé que es lo más probable que llegue a suceder. Siendo esto una visión muy limitada de la construcción del futuro, pues no debemos limitarnos solamente a lo probable desdeñando lo deseable, lo posible, lo factible o lo que pueda representar un escenario totalmente adverso. [HIL 1995]

Hablar de pronóstico es plantearnos algo que puede darse en el futuro, pero no implica considerar todas las alternativas posibles de futuro con las que se pueda interactuar. Para ello, debemos referirnos a algo más amplio y diversificado; esto es, poder visualizar como dilucidar a través de una multiplicidad de escenarios de futuro, y desde esta óptica elegir el futuro más deseable y a la vez factible, para tratar de proceder a participar de manera dinámica e interactiva en su diseño y construcción.

En el entorno estable de las décadas de los 50 y 60 los métodos de pronóstico simples (tales como la mera exploración de la tendencia) eran suficientes para proyectar los futuros picos de carga o la energía consumida. Estas técnicas tan simples proporcionaban, en las décadas mencionadas, una respuesta adecuada a las cuestiones anteriormente planeadas, debido entre otras razones, a la considerable estabilidad de los precios en general (y en particular de los combustibles empleados en la generación eléctrica ) ,al relativamente bajo coste del capital, a las economías de escala que parecían sugerir plantas generadoras cada vez

mayores en un contexto en el que parecía normal que la demanda de energía eléctrica creciera anualmente alrededor de un 7% y a una tendencia demográfica bastante predecible en muchas zonas geográficas. Entre los técnicos de planificación de las compañías eléctricas estaba muy extendida la idea, no sólo de que la demanda aproximadamente se duplicaba cada diez años, sino también la de que, hasta cierto punto, el sector era prácticamente ajeno a la ley de la oferta y la demanda. Una consecuencia de todo lo anterior es que, en las décadas mencionadas, no hubiese necesidad de dedicar gran atención a analizar los factores subyacentes en la demanda de energía eléctrica.

A partir de 1970 se produjo un creciente interés en la modelización econométrica de la demanda eléctrica, debido entre otras razones, a la primera crisis del petróleo en 1973 y a la consiguiente recesión económica del bienio de 1974-1975. Esta disminución en las tasas de crecimiento económico indujo políticas de conservación energética y modificaciones en el uso final de la energía eléctrica. La gran volatilidad de los precios de la energía en los años posteriores a 1973 resultó tan inesperada como la repentina elasticidad de la demanda de los usuarios a los crecientes precios de la energía eléctrica. Los técnicos de planificación eléctrica tuvieron que plantearse varias alternativas, entre las que se encontraban, continuar o no, como hasta entonces, con las plantas convencionales de fuel.

La década de 1990 trajo la ola de desregulación que, teóricamente, rompería el casi monopolio que, de hecho, había supuesto la industria de la energía eléctrica durante décadas en la mayoría de los países. La idea básica pasó a ser que la electricidad, en el futuro, sería tratada como cualquier otra mercancía, en la que el comprador se abastecería del proveedor que mejor precio ofertase. En este nuevo escenario de creciente incertidumbre, las compañías eléctricas tendrían cada vez mayor dificultad para seguir sobrecargando a sus clientes, o abonados, con los costes derivados de decisiones sobre inversiones inapropiadas como consecuencia de predicciones erróneas de la demanda.

En la actualidad en un proceso de planificación del sistema de potencia de un país, uno de los puntos de gran importancia viene a ser el proceso por el cual se obtiene un adecuado estudio de las variables de mayor representatividad en la demanda eléctrica, mediante el análisis del comportamiento histórico el cual permite postular un modelo que sea representativo del proceso.

Si se conoce este modelo (la forma exacta no se conoce), es factible generar pronósticos y si no se conoce el patrón de pronóstico, los datos del pasado pueden inferir en su forma. Por tal razón, la precisión de cualquier pronóstico de demanda está influenciada directamente por los datos disponibles, la metodología aplicada y el horizonte a planificar.

## **2.2 Pronóstico de la demanda**

No cabe duda de que la electricidad constituye una de las principales fuentes energéticas con las que cuenta nuestra civilización. Su empleo abarca un amplísimo abanico de actividades que se extiende desde los usos puramente industriales hasta el consumo doméstico de las familias. Más aún, en un contexto mundial de creciente competencia, no se concibe una economía en crecimiento y competitiva en el ámbito global sin un fluido eléctrico de calidad y a precios altamente competitivos. Esta elevada dependencia ha convertido a la energía eléctrica en un input estratégico que posee unos intensos efectos de arrastre, ya no solo de carácter económico sino también social. De modo que podemos afirmar que vivimos en un mundo que funciona con electricidad. [HIL 1995]

Desde un punto de vista técnico suele hablarse de la energía eléctrica como una “fuente de energía secundaria”, dado que la misma se obtiene a partir de otras fuentes denominadas primarias, básicamente: carbón,

gas y petróleo (combustibles fósiles), hidráulica y nuclear. Al margen de estas y otras consideraciones puramente técnicas, desde un punto de vista económico debemos de reseñar dos importantes características que nos ayudarán a comprender el funcionamiento del mercado eléctrico, P. Murto (1998):

- Con independencia de la fuente primaria utilizada, la energía eléctrica no puede ser almacenada.
- En la mayor parte de sus usos la electricidad juega el papel de un input específico, es decir, el de un factor productivo que no puede ser reemplazado en el corto plazo.

Pensemos que si bien la mayor parte de los instrumentos eléctricos podrían ser adaptados para funcionar con otras fuentes de energía (gasóleo, gas, etc), en el corto plazo estas modificaciones no serían factibles. Estas características dotan al mercado eléctrico de una serie de peculiaridades sumamente interesantes.

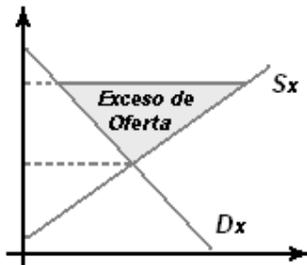


Figura 2.1. Exceso de Oferta.

Fuente: [WEB9]

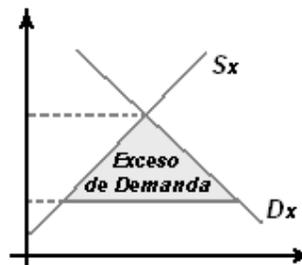


Figura 2.2. Exceso de Demanda.

Fuente: [WEB9]

En la figura 2.1 se muestra lo que en un mercado convencional sería un exceso de oferta. El área sombreada se correspondería con el valor de los stocks acumulados. Sin embargo, en el mercado eléctrico, al ser la electricidad un bien no acumulable, el exceso de oferta, es decir la electricidad producida y no consumida inmediatamente, se perdería sin más. En esta nueva situación el área sombreada representaría las

pérdidas asociadas a una asignación ineficiente de las fuentes primarias, que constituyen recursos escasos y limitados.

Por otra parte, en la figura 2.2 se muestra una situación de exceso de demanda. En un mercado tradicional, el área sombreada representaría el valor de la demanda no atendida. Dada esta situación los demandantes tendrían la posibilidad de esperar a que se atendiera su petición (se formarían colas), ó alternativamente podrían consumir algún sustituto cercano del bien demandado. Sin embargo en el mercado eléctrico no existe la posibilidad de recurrir a sustitutos cercanos, al menos en el corto plazo. Respecto a la primera alternativa, (formación de colas), un retraso en el suministro eléctrico podría tener gravísimas consecuencias económicas y sociales. En la nueva situación el área sombreada representaría un coste de eficiencia asociado a la situación de exceso de demanda.

La demanda de energía eléctrica tiene una variación a lo largo del día. Esta variación es función de muchos factores, entre los que destacan:

- Tipos de industrias existentes en la zona y turnos que realizan en su producción.
- Climatología extremas de frío o calor.
- Tipo de electrodomésticos que se utilizan más frecuentemente.
- Tipo de calentador de agua que haya instalado en los hogares.
- La estación del año y la hora del día en que se considera la demanda.

Un sistema de energía eléctrica debe abastecer de energía a todos los puntos de carga con una buena calidad de servicio. Por lo tanto un sistema eléctrico confiable, el cual asegura buena calidad, debe contar con las siguientes características:

- Entregar energía en forma continua a todos los puntos de carga.
- Los límites de la frecuencia y la tensión deben estar dentro de valores tolerables.
- El sistema debe operar en la medida de lo posible, con costos mínimos y con un mínimo de alteraciones ambientales o ecológicas.

Estas características pueden adquirirse por medio de una planeación exhaustiva de sistema, que permita conocer no sólo su estado actual, sino también las medidas que deben adoptarse para condiciones futuras.

Una de las herramientas útiles en el planeamiento de un sistema eléctrico es la predicción del consumo de carga, la cual permite conocer de antemano la necesidad de expansión del sistema; la finalidad de la predicción siempre será el mejoramiento del servicio, convirtiéndose en uno de los primeros pasos en cualquier proceso de planeamiento de un sistema eléctrico.

Si el pronóstico realizado se apega lo más posible a la realidad se aportará un sin número de parámetros útiles para la planificación, evitando un exceso o baja capacidad de producción, ya que una sobreestimación en los pronósticos dará lugar a malas decisiones de planeación, provocando con esto pérdidas, por lo cual en este trabajo se busca reducir la incertidumbre para conocer la demanda de energía eléctrica en el corto plazo.

El pronóstico para las compañías de electricidad se ha desarrollado a grandes pasos sobre las últimas décadas. Las extrapolaciones de las tendencias históricas del consumo de energía, habían servido bastante bien durante el tiempo en que los precios de producción y las tasas de crecimiento fueron constantes, pero cuando ya no se presentan estas características en la demanda, la extrapolación resultó inadecuada. Estas

técnicas no podían hacer frente a variaciones en tarifas de crecimiento entre los diversos sectores consumidores de energía eléctrica.

Si los pronósticos realizados se apegan lo más posible a la realidad, se aportarán en consecuencia, un sin número de parámetros útiles para la planificación, evitando amenazas en el exceso o baja capacidad de producción. En cambio, una sobrestimación en el pronóstico, dará lugar a malas decisiones, provocando con esto pérdidas económicas.

### **2.2.1 Horizonte de tiempo**

El pronóstico de la demanda de energía, se clasifica principalmente en tres horizontes de tiempo: El pronóstico a corto plazo, el pronóstico a mediano plazo y el pronóstico a largo plazo.

El pronóstico de la demanda de energía eléctrica es a cierto grado incierto sin importar que los límites de confianza se fijen cuidadosamente, el pronóstico se basa fundamentalmente en la probabilidad. El trabajo del pronosticador es entonces proporcionar un pronóstico lo más fiable posible. El encargado de elaborar el pronóstico tiene que identificar el tipo de problema a resolver, tiene que recopilar los datos que requiera, construir un modelo matemático y finalmente generar y validar dicho pronóstico

#### Pronóstico a corto plazo.-

El pronóstico a corto plazo es requerido por los encargados de planificar la operación diaria. Estos pronósticos consisten en proporcionar la demanda de energía eléctrica del sistema sobre un intervalo de horas, días e incluso semanas. Ya que el pronóstico

desempeña un papel importante en la operación y despacho económico de unidades.

La demanda de energía eléctrica tiene variaciones las cuales son naturales, ésta se ve afectada por varios factores tales como condiciones sociales, meteorológicas y económicas; para las cuales se tienen diferentes afectaciones. Las variaciones sociales y las condiciones económicas no tienen ninguna influencia para este pronóstico, por otra parte, las condiciones climatológicas tienen un papel preponderante en el pronóstico de la demanda a corto plazo. Por lo que la demanda, durante los días laborales se diferencian de los fines de semana e igualmente la demanda durante los días festivos son diferentes de los días normales. Por lo que la mayor demanda diaria ocurre normalmente alrededor de la temperatura máxima o mínima dependiendo si la energía se requiere para refrescar o calentar. Con lo que se puede decir que la curva diaria de la demanda sigue normalmente el perfil de temperatura diaria.

#### Pronóstico a mediano plazo.-

Este pronóstico consiste en proporcionar la demanda de energía eléctrica en un intervalo que comprende de semanas, meses e incluso hasta de 5 años.

El pronóstico a mediano plazo está influenciado por más factores aparte de las condiciones atmosféricas. Las variables socioeconómicas también desempeñan un papel importante en el desarrollo de los pronósticos mensuales de la demanda de la energía eléctrica. La inspección de los datos históricos muestra que el patrón del consumo de la demanda de energía, es más o menos cíclico por su propia naturaleza, cambiando únicamente de lugar el pico, debido al crecimiento de la población y por ende el crecimiento de la demanda de energía eléctrica.

Los datos requeridos para el pronóstico de la demanda a mediano plazo, son variables que deben elegidas como resultado de un análisis, además de la consulta con los operadores recomendándose lo siguiente: temperatura máxima absoluta, temperatura media, humedad máxima relativa, velocidad del viento, humedad media, duración brillante del sol, radiación global, precipitación, presión del vapor, días confortables, índice de comodidad, temperatura en la carga máxima, humedad en la carga máxima y número de consumidores conectados.

#### Pronóstico a largo plazo.-

El pronóstico de la demanda a largo plazo es de gran importancia para la planeación de la creación de nuevas plantas de generación, de redes o líneas de transmisión de energía eléctrica, además del consumo de combustibles que se tendrá a largo plazo y de la valoración de los costos de producción de la energía eléctrica. El horizonte del pronóstico, para este caso es normalmente de 5 a 25 años.

El pronóstico a largo plazo de la demanda de energía eléctrica desempeña un papel importante en la planeación del crecimiento de cualquier sistema eléctrico de potencia. Por ejemplo, para llevar a cabo la interconexión entre dos o más sistemas eléctricos de potencia, es necesario realizar estudios extensivos, de todas las condiciones que pueden influir en tales proyectos, así como, un estudio de mercado a futuro que respalde por un largo tiempo el capital que se invertirá.

Para este horizonte de tiempo, las variables que más afectan la demanda son las variables socioeconómicas, ya que consideran el

crecimiento, el producto interno bruto; por otra parte, las variables climatológicas dejan de influir para este horizonte de tiempo.

### **2.2.2 Factores que afectan la demanda eléctrica**

La demanda de energía eléctrica es influenciada por varios factores tales como: variables climatológicas, socioeconómicas y demográficas. De hecho, el número de las variables requeridas depende de la naturaleza del pronóstico, por lo tanto estas variables deben ser seleccionadas cuidadosamente. En el pasado, se sobrestimaba el pronóstico de la demanda de energía, lo cual llevaba a realizar pronósticos rápidos, dando como resultado inversiones de capital en equipo y crecimiento de la red eléctrica, lo cual no sería aprovechado de forma inmediata.

Por tanto, estas variables deben ser seleccionadas cuidadosamente, el criterio de selección para estas variables, se podrá basar en la intuición humana, lo cual tendría que ser validado tanto por un análisis de correlación como para un análisis de contribución al pronóstico.

#### Factores comunes.-

Todos los factores, tales como: variables climatológicas, socioeconómicas y demográficas, actúan directa e indirectamente sobre el patrón de la demanda de energía eléctrica. Algunos de estos factores reflejan cambios importantes en su consumo y en su producción; por lo tanto, la demanda de energía eléctrica se ve influenciada por estos factores. Como ejemplo de estas variables, se tiene: la temperatura, la humedad relativa, la velocidad del viento, las nevadas, el nivel de radiación solar, duración del brillo del sol, el

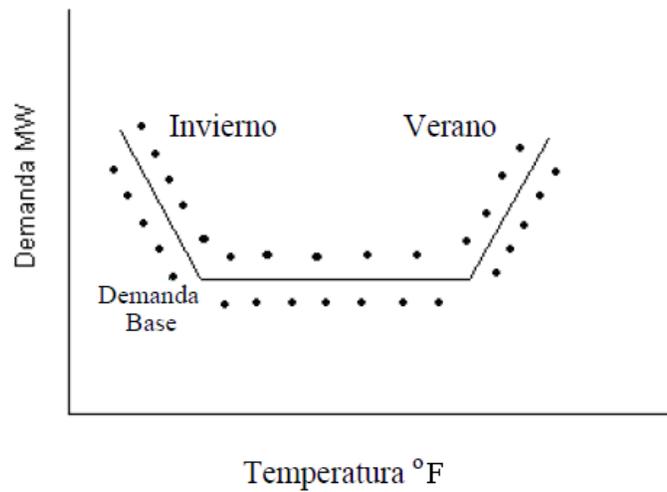
índice de la comodidad, número de consumidores conectados, crecimiento de la población y el producto interno bruto.

#### Factores ocasionales.-

Puesto que además de las variables anteriormente dichas, existen algunas variables que ocasionalmente se presentan, las cuales pueden o no provocar alguna influencia sobre el consumo de energía eléctrica, tal como: los festivales, los acontecimientos religiosos, los días de fiesta nacionales, eventos deportivos, huelgas o catástrofes.

#### Factores estacionales.-

La demanda eléctrica de un sistema eléctrico, también es analizada por periodos o etapas. La demanda durante el día se diferencia de la demanda durante la noche, y la demanda durante días laborales, se diferencia de los fines de semana. La demanda en un día extremadamente caliente, se contrasta de uno extremadamente frío. El crecimiento de demanda eléctrica durante un tiempo económico de auge, se diferencia considerablemente de la demanda durante un periodo de austeridad o recesión. Como se puede apreciar en la figura 2.3, factores como las estaciones del año tienen una gran influencia sobre el crecimiento de la demanda.



**Figura 2.3. Influencia de las estaciones sobre la demanda eléctrica.**

**Fuente: [WEB13]**

### **2.2.3 La naturaleza de la demanda de energía eléctrica**

La demanda de energía en su mayoría es cíclica por su propia naturaleza, la curva de la demanda tiene un patrón que se repite sobre los años. La única diferencia es que el pico de la curva está aumentando constantemente cada año, señalando el crecimiento en la demanda. Así el pronóstico se reduce a un reconocimiento del patrón, para encontrar el crecimiento o tendencia subyacente de la demanda.

### **2.2.4 Influencia del factor temperatura**

La determinación cuantitativa del impacto de la temperatura sobre el consumo de energía eléctrica tiene particular importancia en aquellos países en los que la potencia generadora en reserva es escasa, pudiendo llegar incluso a ser deficitario el suministro de energía

cuando se presentan situaciones meteorológicas muy desfavorables imprevistas (por ejemplo, la repentina llegada de un frente extremadamente frío). Más concretamente, para los distribuidores de tales países una previsión cuantitativa a muy corto plazo (por ejemplo, para el próximo día) de la demanda extra, es una información fundamental, a fin de planificar una utilización racional de las fuentes de producción de las que se dispone, o incluso, en ciertos casos extremos, para evitar la incapacidad de proporcionar el servicio requerido.

El estudio de la influencia de las condiciones meteorológicas en la demanda de electricidad ha sido abordado por diversos autores, pudiendo citarse entre los primeros que se ocuparon de este tema a James Dryar (1944), Williams y Leslie (1953), Maurice Davies (1959), Robert Quayle (1980).

James Dryar puede ser considerado el pionero de los estudios de la influencia de la temperatura en el consumo de electricidad. Para este autor dicho consumo refleja principalmente, por una parte, el nivel de actividad económica y, por otra, las condiciones climáticas. Fue el primero que introdujo el concepto de la demanda base, como aquella parte de la demanda que no se debe, entre otras causas, a las variables atmosféricas. La temperatura no es la única variable considerada en este aspecto, ya que Dryar considera también la posible influencia en la demanda eléctrica de otros factores tales como el nivel de nubosidad y la velocidad del viento. Su trabajo es, sobre todo, descriptivo y en el mismo no se propone ningún modelo analítico.

Maurice Davies propuso un método para estudiar la relación estadística entre las variables meteorológicas y la demanda eléctrica dirigida especialmente a los ingenieros responsables de la planificación del servicio. Su estudio se centra principalmente en los consumos debidos a las necesidades de calefacción e iluminación.

Este autor contempla intervalos de media hora en las correspondientes series temporales y propone unos comportamientos estacionales con un perfil propio para cada día de la semana. Uno de los aspectos más interesantes de este trabajo consiste en introducir un cierto retardo entre la temperatura y la demanda inducida por esta variable.

Victor Panuska realizó un estudio probabilística de previsiones horarias de demanda de potencia eléctrica en el que esta variable dependiente está relacionada con variables climáticas. Este trabajo establece límites probabilísticas para una demanda nominal a la que se añaden, por una parte, una componente residual que satisface una ecuación diferencial referente a la variable dependiente temperatura y una componente estocástica que tiene en cuenta el factor incertidumbre de la demanda. El modelo propuesto por este autor contempla un cierto retardo entre la variable climática y el consumo.

### **2.2.5 Retos en la predicción de la demanda eléctrica**

La predicción automática de demanda eléctrica es un tópico muy complejo y existen varios problemas a la hora de llevarse a cabo. A continuación detallamos algunos de estos problemas:

1.- Determinación de las variables que se deben utilizar en la población. Existen multitud de factores que influyen en el consumo de energía eléctrica como la temperatura, humedad o los consumos anteriores a la fecha de predicción. Además existen otros factores que no son fáciles de determinar como el número de observaciones anteriores que se deben utilizar.

2.- La relación entre la demanda de energía y las variables utilizadas en la predicción no es lineal. Por otro lado, la distribución de los datos

no se ajusta a ningún modelo conocido. Esto supone un problema para las técnicas estadísticas clásicas (que son lineales). Además sugiere la necesidad de utilizar métodos no lineales en la predicción.

3.- La serie de consumos es fuertemente estacional y periódica. Es decir, las características varían significativamente con la estación del año, el día de la semana, etc. Esto supone un problema para las técnicas globales existentes.

### **2.2.6 Implicaciones económicas para las empresas eléctricas**

Para evaluar los beneficios económicos cuantitativamente nos hemos basado en los resultados de la investigación realizada por Hobbs (2004) para 19 compañías eléctricas de Estados Unidos y Canadá.

La mejora de las predicciones eléctricas a corto plazo ayuda a las compañías eléctricas a mejorar la planificación de la producción de cada planta, a reducir la compra-venta de energía, y a tomar mejor las decisiones para establecer el precio de la energía.

El primer concepto por el que se generan beneficios es debido a la reducción de los costes laborables. En efecto, las técnicas neuronales serían más fáciles de utilizar y más rápidas. Ello supone un ahorro de tiempo para los expertos humanos que de otra forma tendrían que observar la serie de consumos para realizar la predicción. Dicho ahorro se cuantifica entre 20 min. Y 90 min. Considerando los costes laborables, en Estados Unidos los beneficios económicos rondarían los \$10 294 por año.

El grueso de beneficios económicos lo componen la planificación de la producción y la compra-venta de energía. La planificación de la producción evita el arranque innecesario de plantas eléctricas y la

generación de energía por medios más costosos de los que se hubieran utilizado con una predicción correcta de la demanda. La compra-venta de energía supone también un coste añadido.

Considérese por ejemplo una compañía cuyo pico diario promedio de energía es de 10 000 Mw. Supongamos que se sobreestima la demanda en un 4% lo que significa producir 400 Mw. más de lo necesario. Si consideramos un coste por unidad de \$60/Mw/día, una reducción del 1% en la predicción ahorraría:

$$(1/4) (400 \text{ Mw}) (\$60/\text{Mw}/\text{día}) = \$6\,000 / \text{día}$$

A lo largo del año, y suponiendo que la demanda se sobreestima en promedio el 50% de los días, esto supone unos beneficios aproximados de \$1 100 000 / año.

Por otro lado, si la predicción subestima la demanda en un 4% y el periodo pico dura 5 h. entonces es necesario obtener:

$$(0,04 * 10\,000 \text{ Mw.} * 5\text{h}/\text{día}) = 2000 \text{ Mwh} / \text{ día}$$

Comprándola en el mercado o generándola con plantas de arranque rápido como turbinas. Si consideramos que el coste adicional es de \$10/Mwh esto supone un coste añadido de \$20 000/día. Asumiendo que en promedio se subestima la demanda un 50% de las veces esto supone un coste añadido de

$$(\$20\,000/\text{día} * 365 \text{ días/año} * 0,5) \text{ equivalente a } \$3\,650\,000 / \text{año}$$

Sumando los beneficios de subestimar y sobreestimar la demanda, los beneficios económicos serían de \$ 4 750 000/año para un 1% de reducción en la tasa de error.

Finalmente, volviendo al caso particular de las eléctricas americanas y, considerando una serie de gastos diversos, el beneficio neto por año y planta es de aproximadamente \$700 000 para una reducción de un 1,5% del error. Por lo tanto la reducción del error en los pronósticos aunque pequeños en porcentaje, supone grandes beneficios económicos para las empresas eléctricas.

### **2.3 Redes Neuronales Artificiales**

Existe en el hombre un deseo profundo de poder reproducir la habilidad cognoscitiva por medios artificiales. La fascinación que la inteligencia como materia de estudio ha suscitado al género humano, puede verse reflejada en la aparición de una rama íntegra del estudio científico llamada "Inteligencia Artificial" a secas o también estudio de la inteligencia.

Una de las múltiples ramas por las cuales se ha desarrollado la investigación es el desarrollo de las llamadas "redes neuronales". Una **red neuronal** es el intento de poder realizar una simulación computacional del comportamiento de partes del cerebro humano mediante la réplica en pequeña escala de los patrones que éste desempeña para la formación de resultados a partir de los sucesos percibidos.

Concretamente, se trata de poder analizar y reproducir el mecanismo de aprendizaje y reconociendo de sucesos que poseen los animales más evolucionados.

### 2.3.1 Definición de las RNA

Es un sistema compuesto por un gran número de elementos básicos (neuronas artificiales), agrupados en capas y que se encuentran altamente interconectados. Esta estructura posee varias entradas y salidas, las cuales serán entrenadas para reaccionar, de una manera deseada, a los estímulos de entrada. [QUI 2007]

Estos sistemas emulan, de una cierta manera, al cerebro humano. Requieren aprender a comportarse y alguien debe encargarse de enseñarles o entrenarles, en base a un conocimiento previo del entorno del problema.

Las redes neuronales son un elemento importante de las denominadas tecnologías de Inteligencia Artificial (IA). Así, las principales características que diferencian a las redes neuronales de otras tecnologías de IA son:

- Su capacidad de aprendizaje a partir de la experiencia (entrenamiento). Normalmente, para la elaboración de un programa informático es necesario un estudio detallado de la tarea a realizar para después codificarla en un lenguaje de programación. Pero, las redes neuronales pueden ser entrenadas para realizar una determinada tarea sin necesidad de un estudio a fondo ni programarla usando un lenguaje de programación. Además; las redes neuronales pueden volver a entrenarse para ajustarse a nuevas necesidades de la tarea que realizan, sin tenerse que reescribir o revisar el código (cosa frecuente en programas tradicionales).
- Su velocidad de respuesta una vez concluido el entrenamiento. Se comportan también en este caso de manera similar a como lo hace el cerebro: los seres humanos no necesitamos pensar mucho para identificar un objeto o una palabra; si es que

anteriormente tuvimos un aprendizaje previo donde hayamos aprendido a identificar este objeto o esa palabra.

- Fácil inserción dentro de la tecnología existente. Una red individual puede ser entrenada para desarrollar una única y bien definida tarea (tareas complejas, que hagan múltiples selecciones de patrones, requerirán sistemas de redes interconectadas). Con las herramientas computacionales existentes, una red puede ser rápidamente entrenada, comprobada, verificada y trasladada a una implementación hardware de bajo coste. Por lo tanto, no se presentan dificultades para la inserción de redes neuronales en aplicaciones específicas, por ejemplo de control, dentro de los sistemas existentes. De esta manera, las redes neuronales se pueden utilizar para mejorar sistemas en forma incremental y cada paso puede ser evaluado antes de acometer un desarrollo más amplio.
- Tolerancia a fallos: las redes neuronales fueron los primeros métodos computacionales con la capacidad inherente de tolerancia a fallos. Comparados con los sistemas computacionales tradicionales ,los cuales pierden su funcionalidad cuando sufren un pequeño error de memoria, en las redes neuronales, si se produce un fallo en un número no muy grande de neuronas y aunque el comportamiento del sistema se ve influenciado, no sufre una caída repentina. La razón por la que las redes neuronales son tolerantes a los fallos es que tienen su información distribuida en las conexiones entre neuronas, existiendo cierto grado de redundancia en este tipo de almacenamiento. La mayoría de los ordenadores algorítmicos y sistemas de recuperación de datos almacenan cada pieza de información en un espacio único, localizado y direccionable. En cambio, las redes neuronales almacenan información no localizada. Por lo tanto,

la mayoría de las interconexiones entre los nodos de la red tendrán sus valores en función de los estímulos recibidos, y se generará un patrón de salida que represente la información almacenada.

- Su robustez, en el sentido de que el conocimiento adquirido se encuentra repartido por toda la red, de forma que si se lesiona una parte se continúan generando cierto número de respuestas correctas (en este caso también hay cierta analogía con los cerebros parcialmente dañados).

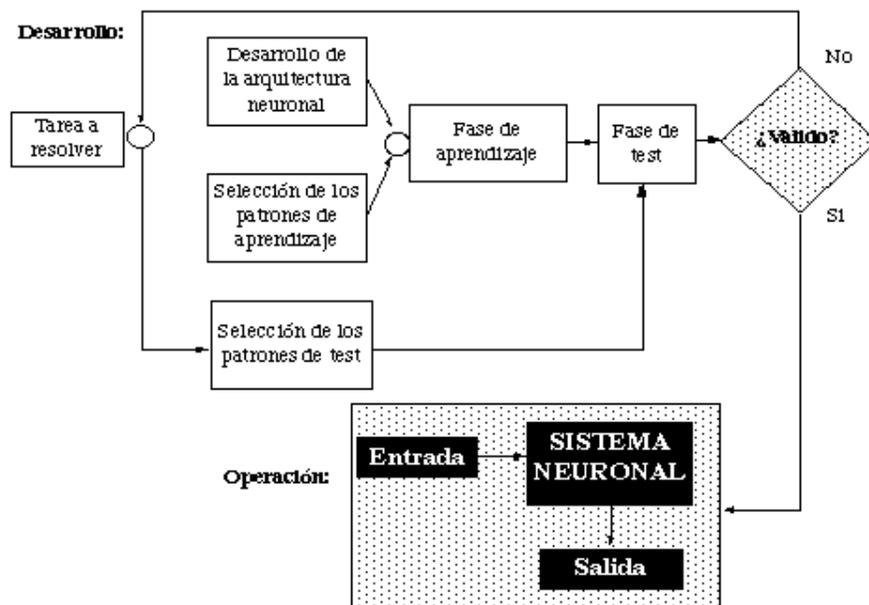
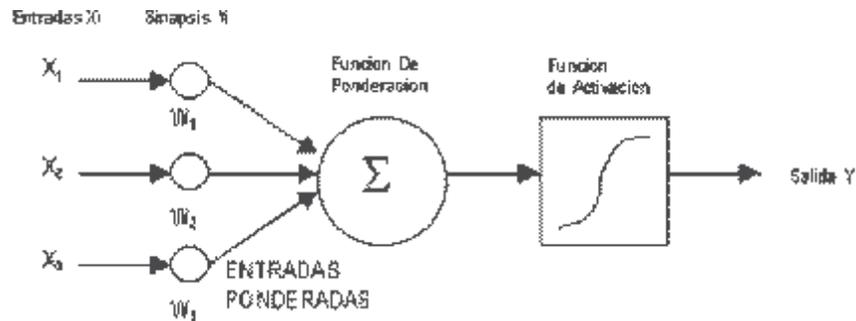


Figura 2.4. Modelo de trabajo con Redes Neuronales.

Fuente: [WEB2]

El modelo de neurona artificial modela la neurona como una serie de funciones que se componen entre ellas siendo los resultados unas los parámetros de otras, así la función de ponderación hace uso de los valores que le llegan de las entradas y los pesos de las sinapsis y la función de activación toma este valor para transformarlo en el estado

de la neuronas mediante la interacción de estas funciones se procesa la información.



**Figura 2.5. Representación de una Neurona Artificial.**

Fuente: [WEB1]

### **Función de propagación o ponderación:**

Esta función se encarga de transformar las diferentes entradas que provienen de la sinapsis en el potencial de la neurona.

Normalmente se usa como función de propagación la suma ponderada de las entradas multiplicadas por los pesos. En esta función se interpreta como un regulador de las señales que se emiten entre neuronas al ponderar las salidas que entran a la neurona.

Otra regla de propagación usada es la distancia euclídea. Usada en los mapas de kohonen y algunas redes competitivas. En ella, los pesos sinápticos funcionan de manera distinta al anterior ya que lo que hacen es aproximarse lo máximo posible al vector de entrada. Es utilizada en redes no supervisadas para que se ajuste a los patrones.

Otra versión de esta función es la misma pero con la distancia de Manhattan esto es en vez de usar el cuadrado usamos el valor absoluto. En esta regla de propagación los pesos tienen la misma interpretación que la anterior, da la medida del parecido entre el patrón de entrada  $X$  y los pesos  $W$ .

### **Función de activación:**

La función de activación combina el potencial postsináptico, que nos proporciona la función de propagación, con el estado actual de la neurona para conseguir el estado futuro de activación de la neurona. Sin embargo, es muy común que las redes neuronales no tomen su propio estado como un parámetro y que por tanto no se considere. Esta función es normalmente creciente monótona y podemos citar las funciones más comunes:

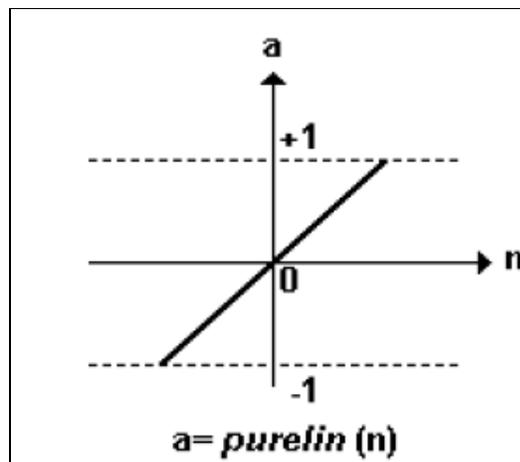
#### Lineal

Algunas redes neuronales usan esta función de activación como el Adeline por su eficiencia y facilidad. Para esta función se tiene:

$$a = f(n) = K * n$$

Donde k es el factor de amplificación en la región lineal de operación.

Esta función está representada por la figura 2.6:



**Figura 2.6. Función lineal.**

Fuente: [WEB12]

### Escalón

Esta función es la más usada para redes neuronales binarias ya que no es lineal y es muy simple. Algunas redes que usan esta función son el Perceptrón y Hopfield. Para redes que trabajan en el rango  $[-1,1]$  se usa la función signo. Para esta función se tiene:

$$a = f(n) \quad \begin{cases} 1 & \text{si } n \geq 0 \\ 0 & \text{si } n < 0 \end{cases}$$

Donde  $n$  es el campo local inducido de la neurona que es:

$$ak = \sum wk_j n_j + bk$$

Esta función está representada por la figura 2.7:

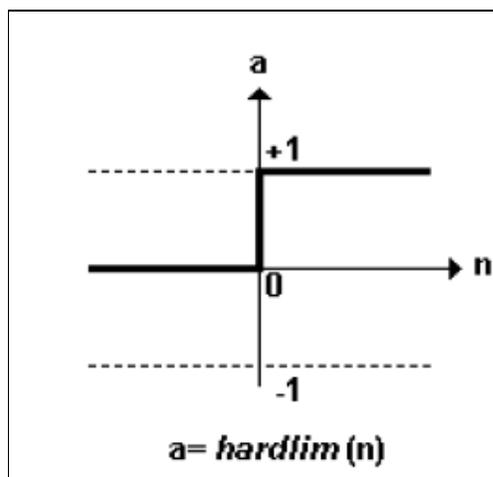


Figura 2.7. Función escalón.

Fuente: [WEB12]

### Hiperbólicas o tangenciales

Las redes con salidas continuas, como el Perceptrón multicapa con retropropagación, usan esta función ya que su algoritmo de aprendizaje necesita una función derivable. La función está representada por:

$$a = \frac{e^{kn} - e^{-kn}}{e^{kn} + e^{-kn}}$$

Donde  $k > 0$  y rango = (-1,1)

La figura 2.8 muestra a la función tangencial:

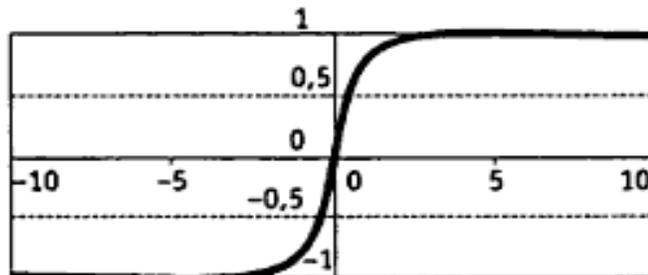


Figura 2.8. Función tangencial.

Fuente: [WEB12]

Donde  $k = 1$

### **Función de salida:**

Esta función convierte el estado de la neurona en la salida hacia la siguiente neurona que se transmite por las sinapsis. Usualmente no

se considera y se toma la identidad, esto es, de manera que la salida es el propio estado de activación de la neurona.

Existen algunas redes que transforman su estado de activación en una salida binaria y para eso usan la función escalón antes mostrada como salida.

Otra opción, consiste en usar funciones probabilísticas como en la máquina de Boltzman. Las redes con este tipo de salidas no tienen un comportamiento determinista.

### **2.3.2 Historia de las RNA**

La era moderna de las redes neuronales se cree que comenzó en 1943 gracias a McCullough y Pitts, quienes describieron el cálculo lógico de las redes neuronales y perfilaron el primer módulo formal de una neurona elemental.

En la década de los cincuenta, Minsky comienza a construir la primera neurocomputadora (basada en modelos de redes neuronales que imitan al cerebro).

En 1962, Frank Rosenblatt presenta los resultados de una máquina a la que denominó "Perceptrón", la cual reproducía una estructura neuronal muy simplificada, capaz de aprender a reconocer y clasificar determinadas figuras.

En la misma década, Minsky y Pappert (autoridades de la IA clásica) publicaron un libro en el que se ponían de manifiesto las limitaciones de los perceptrones de una capa. Esto hará que se pierda interés en el campo de las redes neuronales hasta la década de los 80, en que el estudio de nuevas arquitecturas de redes y la mayor potencia de los ordenadores permiten el diseño de redes muy eficientes en tareas en las que otros procedimientos de tipo simbólico encuentran dificultades.

Así, en 1982 J. Hopfield describe las "redes de Hopfield" en las que se utilizan funciones de energía para entender las redes dinámicas. Cohen y Grossberg desarrollan en el 83 el principio de la memoria direccional. En 1986 Rumulhart, Hunton y Williams redescubren el algoritmo de "back-propagation" (desarrollado en 1974 por Paul Werbor) para el aprendizaje de redes neuronales. Por estas fechas, y gracias a las nuevas tecnologías de fabricación de microchips, comienzan a construirse redes neuronales implementadas en silicio (mucho más rápidas que las de software).

Actualmente, el uso de redes neuronales se ha extendido bastante en el mercado de software doméstico, dejando de estar restringidas a los entornos de investigación y a las grandes empresas. De esta forma, se pueden encontrar modelos de redes neuronales en programas de reconocimiento de voz, en juegos de ordenador, programas de contabilidad, tutores, y muchos otros.

### **2.3.3 Estructura de las RNA**

Las redes neuronales típicamente están formadas por una serie de capas de neuronas que están unidas entre si mediante sinapsis.

Las neuronas artificiales como unidades independientes no son muy eficaces para el tratamiento de la información y se agrupan en estructuras más grandes, las redes de neuronas artificiales o redes neuronales.

#### **Niveles de Neuronas:**

La distribución de neuronas dentro de la red se realiza formando niveles o capas de un número determinado de neuronas cada una. A

partir de su situación dentro de la red se pueden distinguir tres tipos de capas:

- De entrada: Estas capas reciben la información desde el exterior.
- De Salida: Estas capas envían la información hacia el exterior.
- Ocultas: Son capas que solo sirven para procesar información y comunicar otras capas.

A continuación en la figura 2.9 se muestra una red neuronal artificial perceptrón simple con  $n$  neuronas de entrada,  $m$  neuronas en su capa oculta y una neurona de salida.

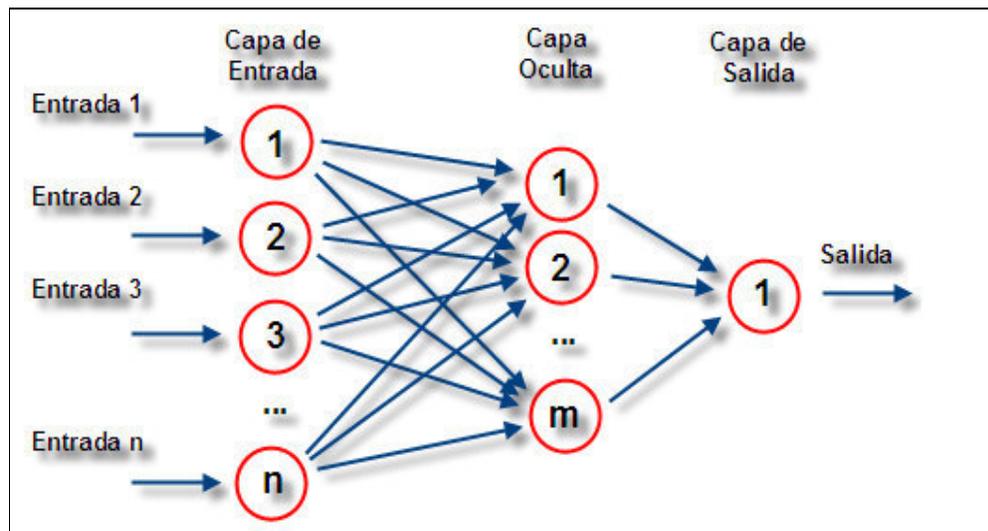


Figura 2.9. Niveles de la neurona.

Fuente: [WEB14]

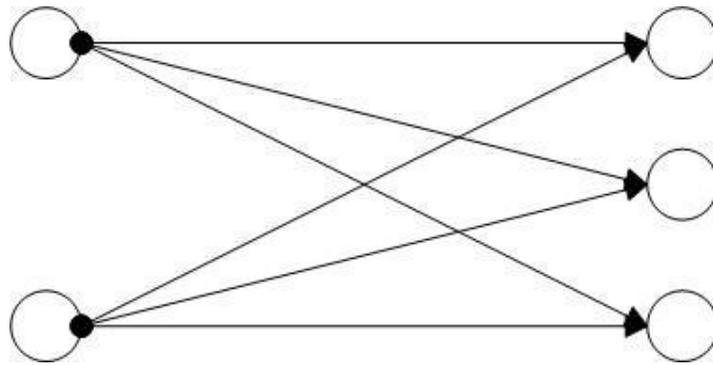
### Forma de Conexión de las Capas:

Las neuronas se conectan unas a las otras usando sinapsis, y estas uniones pueden formar distintas estructuras; así como:

### Unión Todos con Todos

Consiste en unir cada neurona de una capa con todas las neuronas de la otra capa. Este tipo de unión es el más usado en las redes neuronales, se usa en todo tipo de uniones desde el Perceptrón multicapa a las redes de Hopfield o BAM.

A continuación se muestra un ejemplo de la unión Todos con Todos de las neuronas:



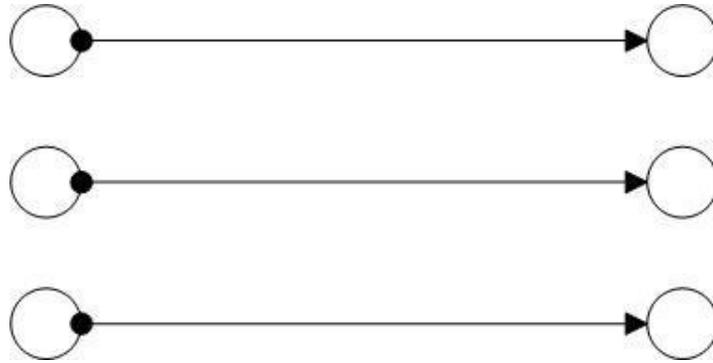
**Figura 2.10. Conexión entre neuronas – Todos con todos.**

**Fuente: [WEB11]**

### Unión Lineal

Consiste en unir cada neurona con otra neurona de la otra capa. Este tipo de unión se usa menos que el anterior y suele usarse para unir la capa de entrada con la capa procesamiento, si la capa de entrada se usa como sensor. También se usa en algunas redes de aprendizaje competitivo.

A continuación se muestra un ejemplo de la unión lineal entre neuronas.



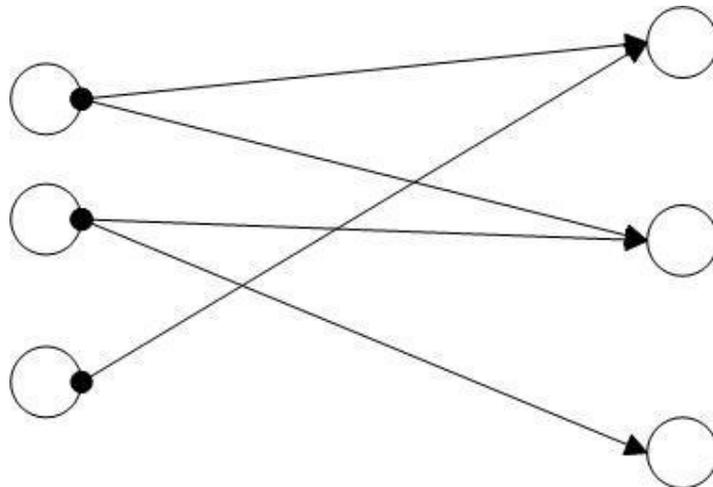
**Figura 2.11. Conexión entre neuronas – Unión lineal.**

Fuente: [WEB11]

Predeterminado

Este tipo de unión aparece en redes que tienen la propiedad de agregar o eliminar neuronas de sus capas y de eliminar también conexiones.

A continuación se muestra un ejemplo de la unión predeterminada entre neuronas:



**Figura 2.12. Conexión entre neuronas – Predeterminado.**

Fuente: [WEB11]

#### **2.3.4 Mecanismos de aprendizaje de las RNA**

Las redes neuronales manejan dos tipos de información.

La primera, es la información volátil, que se refiere a los datos que se están usando y varían con la dinámica de la computación de la red, se encuentra almacenada en el estado dinámico de las neuronas.

El segundo tipo de información que manejan las redes neuronales, es la información no volátil que se mantiene para recordar los patrones aprendidos y se encuentra almacenada en los pesos sinápticos.

El aprendizaje de las redes neuronales, es el proceso de presentar los patrones a aprender, a la red y el cambio de los pesos de las conexiones sinápticas usando una regla de aprendizaje.

La regla de aprendizaje consiste en algoritmos basados en formulas matemáticas, que usando técnicas como minimización del error o la optimización de alguna "función de energía", modifican el valor de los pesos sinápticos en función de las entradas disponibles y con ello optimizan la respuesta de la red a las salidas que deseamos.

El aprendizaje se basa en el entrenamiento de la red con patrones, que usualmente son llamados patrones de muestra o entrenamiento. El proceso usual del algoritmo es que la red ejecuta los patrones iterativamente, cambiando los pesos de las sinapsis, hasta que convergen a un conjunto de pesos óptimos que representan a los patrones lo suficientemente bien, entonces mostrará una respuesta satisfactoria para esos patrones. Esto es, sus pesos sinápticos se ajustan para dar respuestas correctas al conjunto de patrones de entrenamiento.

Sin embargo, hay que destacar que algunas redes no tienen un aprendizaje iterativo como el descrito en el párrafo anterior de

presentar los patrones una y otra vez hasta que la red se establece para dar resultados correctos, si no que los pesos de las sinapsis son calculados previamente a partir de los patrones, como en la red de Hopfield.

Podemos distinguir tres tipos de aprendizaje:

**Aprendizaje supervisado:**

Es el modo más intuitivo y consiste en que la red dispone de los patrones de entrada y los patrones de salida que deseamos para esa entrada y en función de ellos se modifican los pesos de las sinapsis para ajustar la entrada a esa salida.

**Aprendizaje no supervisado:**

Consiste en no presentar patrones objetivos, si no solo patrones de entrada, y dejar a la red clasificar dichos patrones en función de las características comunes de los patrones.

**Aprendizaje reforzado:**

Usa una formula híbrida, el supervisor no enseña patrones objetivos si no que solo le dice se acierta o falla en su respuesta ante un patrón de entrada.

### **2.3.5 Topología de las RNA**

El perceptrón simple (Monocapa)

El perceptrón es una red de alimentación directa, esto es la información fluye desde la capa de entrada hacia la capa de salida. Fue desarrollado por F. Rosenblatt hacia final de la década de los cincuenta basándose en la regla de aprendizaje de hebb y de los modelos de neuronas biológicas de McCulloch y Pitts.

El Perceptrón es un clasificador, asigna a un vector de N valores un valor binario, usando una transformación no lineal. Así cada vector pertenece a una de las particiones que crea el perceptrón.

El perceptrón es una máquina de computación universal y tiene la expresividad equivalente a la lógica binaria ya que podemos crear un perceptrón que tenga el mismo comportamiento que una función booleana NAND y a partir de esta función se puede crear cualquier otra función booleana.

### **Arquitectura del perceptrón simple:**

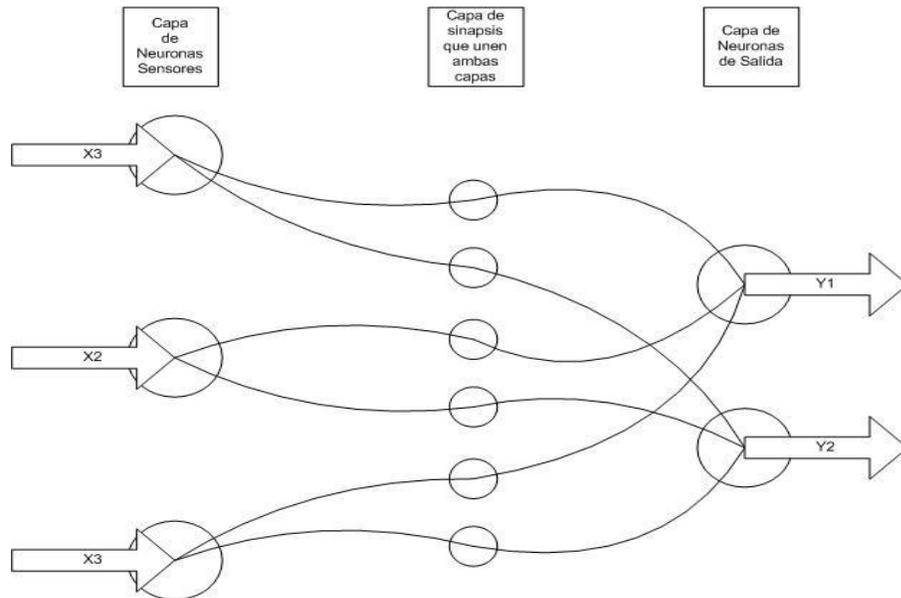
El perceptrón simple es una red que consta de dos capas de neuronas.

Esta red admite valores binarios o bipolares como entrada para los sensores y los valores de su salida están en el mismo rango que los de entrada.

La función de la primera capa es hacer de sensor, por ella entran las señales a la red.

La segunda capa realiza todo el procesamiento. La manera de interconexión de ambas capas es todas con todas esto es, cada neurona de la primera capa está unida con todas las de la segunda capa.

A continuación se muestra la arquitectura del perceptrón simple con las funciones que cumplen las diferentes capas:



**Figura 2.13. Arquitectura del Perceptrón Monocapa.**

Fuente: [WEB11]

### **Dinámica del perceptrón simple:**

El funcionamiento para ejecutar un patrón de la red es el siguiente:

- 1 Se establece el patrón de entrada en los sensores, la capa de entrada.
- 2 Se actualizan las neuronas de la capa de salida.

Las neuronas se actualizan de la siguiente manera:

Sea el potencial de la neurona  $i$ ,

El peso asociado a la sinapsis que une la neurona  $i$  de la capa actual y  $j$  de la capa de sensores.

El estado del sensor  $j$ .

Entonces

Y el estado de la neurona es o bien la función escalón si las entradas de la red son binarias o bien la función signo si las entradas son bipolares  $\{-1, 1\}$

$$\text{estado neurona } J = \text{Signo}(\text{Sumatorio}(\text{Peso}(ij) * \text{Estado}(j)))$$

### **Aprendizaje del perceptrón simple:**

Los pasos para que la red aprenda una lista de patrones son los siguientes:

- 1 Tomar un patrón al azar de la lista.
  - 2 Se establece el patrón de entrada en los sensores, la capa de entrada.
  - 3 Se establecen los valores deseados en las neuronas de la capa de salida.
  - 4 Se actualizan las neuronas de la capa de Salida.
  - 5 Solicitar que aprendan todas las sinapsis.
  - 6 Si las sinapsis han cambiado volver al paso 1.
- Si no han cambiado la red se ha estabilizado y paramos.

Las sinapsis que une las neuronas  $i$ ,  $j$  aprenderá de la siguiente manera:

Sea

- $E_i$  = el estado de la neurona de la capa de entrada  $i$ .
- $P_{ij}$  = el peso actual asociado a la sinapsis que une la neurona  $i$  de la capa de entrada y la neurona  $j$  de la capa de salida.
- $E_j$  = el estado de la neurona de la capa de salida  $j$ .
- $S_j$  = el valor deseado para esa neurona.
- $P_{ij\text{nuevo}}$  = el peso  $P_{ij}$  actualizado.
- TASA = es una constante entre 0 y 1 que indica cuanto aprende la red.

$$P_{ij\text{nuevo}} = P_{ij} + \text{Tasa} * ((E_j - S_j) * E_i)$$

Hay que destacar que el perceptrón aprende solo cuando se equivoca al clasificar el patrón. Si clasifica correctamente el patrón, esto es, entonces con lo que no hay aprendizaje.

### El Perceptrón Multicapa

El perceptrón simple tiene una serie de limitaciones muy importantes. La más importante es su incapacidad para clasificar conjuntos que no son linealmente independientes.

Esto quedó patente en la obra Perceptrons que en 1969 demostró que un perceptrón es incapaz de aprender una función tan fácil como la XOR.

Este modelo es una ampliación del perceptrón a la cual añade una serie de capas que, básicamente, hacen una transformación sobre las variables de entrada, que permiten eludir el problema anterior.

Esto acaba con el problema del perceptrón, convirtiendo las funciones linealmente no independientes en linealmente independientes gracias a la transformación de la capa oculta.

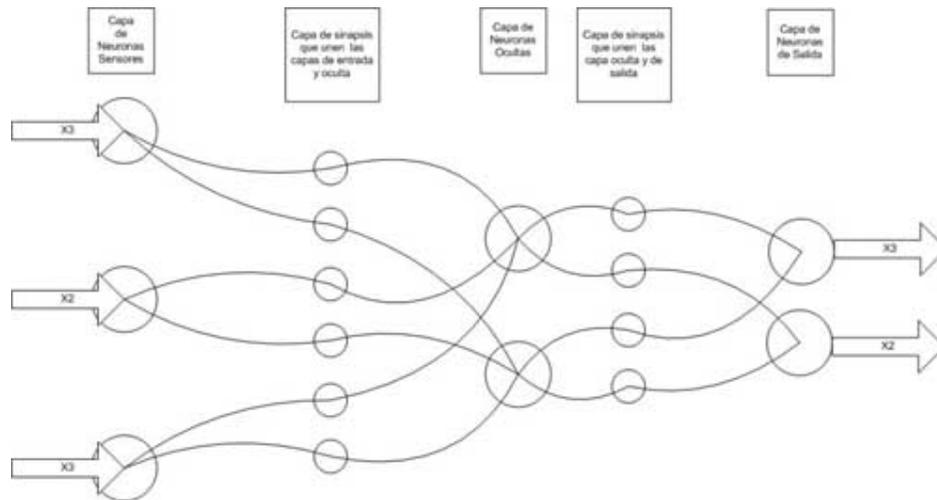
Además el perceptrón multicapa admite valores reales. Podemos decir que el perceptrón multicapa es un modelador de funciones universal.

### **Arquitectura del perceptrón multicapa**

El perceptrón multicapa consta de una capa de entrada y una capa de salida y una o más capas ocultas. Dichas capas se unen de forma total hacia delante, esto es, la capa entrada se une con la primera capa oculta y esta con la siguiente y la última capa oculta se une con

la capa de salida. Los valores que el perceptrón multicapa acepta son reales.

A continuación se presenta el gráfico representativo de la arquitectura del perceptrón multicapa donde se muestran la forma de unión de las capas.



**Figura 2.14. Arquitectura del Perceptrón Multicapa.**

Fuente: [WEB11]

### 2.3.6 Aplicaciones de las RNA

Las características de las redes neuronales hacen que sus posibles aplicaciones sean muy amplias. Algunas de las aplicaciones más destacadas son:

- Reconocimiento de patrones de clasificación:  
Reconocimiento de voz, de caracteres manuscritos  
Análisis y reconocimiento de imágenes, formas  
Diagnostico clínico.
- Análisis de series temporales y predicción:  
Modelos meteorológicos.

- Predicción del comportamiento.
- Predicción de series temporales.
- Robótica

En general, las redes neuronales tratan de resolver de forma eficiente problemas que pueden encuadrarse dentro de tres amplios grupos: optimización, reconocimiento y generalización. Estos tres tipos engloban un elevado número de situaciones, lo que hace que el campo de aplicación de las redes neuronales en la gestión empresarial sea muy amplio. Los libros de Refenes (1995) y Deboeck y Kohonen (1998) recogen una amplia colección de trabajos aplicados en contabilidad y finanzas.

#### Optimización

En los problemas de optimización se trata de determinar una solución que sea óptima. En la gestión empresarial, son decisiones de optimización encontrar los niveles adecuados de tesorería, de existencias, de producción, construir de carteras óptimas, etc.

#### Reconocimiento

En los problemas de reconocimiento se entrena una red neuronal con inputs como sonidos, números, letras y se procede a la fase de test presentando esos mismos patrones con ruido. Este es uno de los campos más fructíferos en el desarrollo de redes neuronales y casi todos los modelos de red neuronal han sido aplicados con mayor o menor éxito.

#### Generalización

En los problemas de generalización la red neuronal se entrena con unos inputs y el test se realiza con otros casos diferentes. Problemas típicos de generalización son los de clasificación y predicción. Son problemas de generalización tratar de predecir la quiebra de las empresas a partir de su información contable o la concesión de

préstamos, la calificación de obligaciones, la predicción en los mercados de valores, etc.

En los problemas de clasificación se trata de asignar a cada caso su clase correspondiente, a partir de un conjunto de ejemplos.

La predicción ha sido una de las aplicaciones que más pronto despertaron el interés de los estudiosos de las redes neuronales. El análisis técnico pretende predecir las cotizaciones a partir de la evolución histórica de precios y volúmenes de negociación. El análisis fundamental trata de valorar los factores económicos más importantes del entorno y contempla la evolución económico-financiera de las empresas.

### **2.3.7 Ventajas y desventajas de las RNA**

Hay muchas buenas razones para el uso de redes neuronales y los avances en este campo incrementarán su popularidad. Son excelentes como clasificadores/reconocedores de patrones y pueden ser usadas donde las técnicas tradicionales no funcionan. Las redes neuronales pueden manejar excepciones y entradas de datos anormales, muy importante para sistemas que manejan un amplio rango de datos (sistemas de radar y sonar, por ejemplo). Muchas redes neuronales son biológicamente plausibles, lo que significa que pueden proveer pistas de como trabaja el cerebro según progresen. Avances en la neurociencia también ayudarán al avance en las redes neuronales.

Existen unas cuentas desventajas en las redes neuronales. La mayoría de ellas, de todas maneras, padecen nuestra falta de hardware. La capacidad de las redes neuronales radica en su habilidad de procesar información en paralelo (esto es, procesar

múltiples pedazos de datos simultáneamente). Desafortunadamente, las máquinas hoy en día son serie - sólo ejecutan una instrucción a la vez. Por ello, modelar procesos paralelos en máquinas serie puede ser un proceso que consuma mucho tiempo. Como todo en este día y época, el tiempo es esencial, lo que a menudo deja las redes neuronales fuera de las soluciones viables a un problema.

Otros problemas con las redes neuronales son la falta de reglas definitorias que ayuden a construir una red para un problema dado - hay muchos factores a tomar en cuenta: el algoritmo de aprendizaje, la arquitectura, el número de neuronas por capa, el número de capas, la representación de los datos y mucho más. De nuevo, con el tiempo siendo tan importante, las compañías no pueden permitirse invertir tiempo de desarrollo para resolver los problemas eficientemente. Esto puede cambiar al avanzar las redes neuronales.

### **2.3.8 Cuestiones a resolver al trabajar con una red neuronal**

Muchos problemas aparecen cuando se trabaja con redes neuronales. Primeramente se debe analizar el dominio del problema y decidir a que clase pertenece. Luego debe decidirse si una red neuronal es adecuada para resolver dicho problema. Esto es lo que se llama: *etapa preliminar*. Concluida esta etapa, las siguientes preguntas han de responderse:

a.- Origen de los datos.

\_ ¿Qué datos son de importancia para la situación del problema definido?

\_ ¿Qué variables son relevantes?

\_ ¿De dónde pueden obtenerse los datos?

b.- Preparación y codificación de los datos.

\_ ¿Cómo preparar y codificar los datos?

c.- Topología de la red (dependiendo parcialmente del ítem b).

\_ ¿Qué tipo de red debe escogerse?

\_ ¿Cuántas capas ocultas y con cuántas neuronas son necesarias?

\_ ¿Cuántas neuronas en la capa de salida (según la codificación escogida)?

\_ ¿Qué tipos de neuronas deben escogerse?

\_ ¿Qué regla de aprendizaje escoger?

d.- Decisiones concernientes al proceso de aprendizaje.

\_ ¿Cuántos ciclos de aprendizaje?

\_ ¿Qué inicialización para los pesos?

## **2.4 Inteligencia artificial**

### **2.4.1 Inteligencia**

Inteligencia puede ser definido como un conjunto de propiedades de la mente. Estas propiedades incluyen la habilidad para planificar, resolver problemas y en general: razonar.

Entonces una definición simple sería: Inteligencia es la capacidad para tomar la decisión correcta, dado un conjunto de entradas y una variedad de posibles acciones. [JON 2008]

Esta simple definición de inteligencia (tomar la decisión correcta), se puede aplicar no solo a humanos, sino también a animales que muestran un comportamiento racional. Sin embargo, la inteligencia que presentan los seres humanos es mucho más compleja que la de los animales.

La misma analogía se puede aplicar para la Inteligencia Artificial aplicada a sistemas de computadora. Por ejemplo, es posible construir un programa que juegue muy bien el ajedrez; sin embargo no sabrá nada acerca del juego damas, ni como preparar una buena taza de té.

### **2.4.2 Inteligencia artificial**

Se denomina inteligencia artificial a la rama de la ciencia informática dedicada al desarrollo de agentes racionales no vivos. Siendo un agente, cualquier cosa capaz de percibir su entorno, procesar tales percepciones y actuar en su entorno.

De acuerdo a la *Encyclopedia Of Artificial Intelligence*:

“La IA es un campo de la ciencia y la ingeniería que se ocupa de la comprensión, desde el punto de vista informático, de lo que denomina comúnmente comportamiento inteligente. También se ocupa de la creación de artefactos que exhiben este comportamiento.”

Otras definiciones:

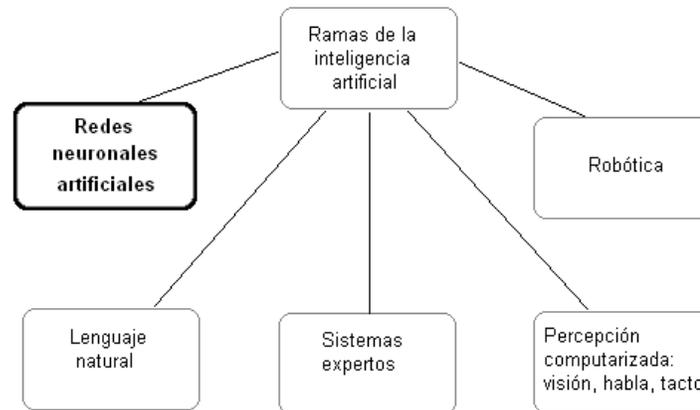
“La inteligencia artificial es la ciencia de construir máquinas que hacen cosas que realizadas por el hombre requieren el uso de la inteligencia” (Marvin Minsky).

“La inteligencia artificial es el estudio de las ideas que permiten ser inteligentes a los ordenadores” (P. H. Winston).

“Parte de la informática que estudia procesos simbólicos, razonamientos no algorítmicos y representaciones simbólicas del conocimiento” (B.G. Buchanan y E. A. Feigenbaum).

### 2.4.3 Ramas de la Inteligencia Artificial

Los sistemas de IA se pueden clasificar en las siguientes categorías:



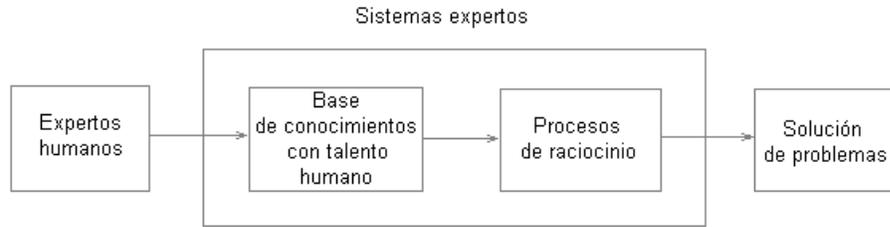
**Figura 2.15. Ramas de la Inteligencia Artificial.**

**Fuente: [WEB10]**

#### Los sistemas expertos

Son programas que utilizan procesos de razonamiento similares a los humanos, en vez de técnicas de computación, para resolver problemas en campos específicos del saber.

Estos procesos programados, que simulan el razonamiento humano, a su vez, están basados en conocimientos humanos experimentales, o habilidades que se codifican en el programa en una estructura denominada 'base de conocimientos'.



**Figura 2.16. Mecanismo de un Sistema Experto.**

**Fuente: [WEB10]**

Con este mecanismo codificado de cognición y razonamiento, los sistemas expertos pueden afrontar problemas insolubles desde la perspectiva de los ordenadores de programación convencional. Varios expertos han demostrado su viabilidad comercial en campos tales como:

- Electromedicina
- Diagnóstico médico
- Configuración de sistemas informáticos
- Prospección petrolílica
- Proceso de información

#### Los sistemas de lenguaje natural

Incluyen programas que comprenden el idioma en que se expresa el usuario: por ejemplo, el inglés.

Estos programas proporcionan un medio fácil de aprender comunicación con los ordenadores, pues eliminan la necesidad de aprender un lenguaje de computación.

Los sistemas de lenguaje natural más comunes, que satisfacen las necesidades más inmediatas, son aquellos que sirven de interfase con las bases de datos. Estos sistemas de lenguaje natural permiten

que el usuario consulte la base de datos en un idioma conocido y no en los lenguajes informáticos usuales de consulta de base de datos.

Estos sistemas pueden precisar ambigüedades y resolverlas de diferentes modos. Así los sistemas de lenguaje natural hacen accesible la información de las bases de datos a los no profesionales de la informática que necesitan o desean tener acceso a los ordenadores.

---

HOW MANY COOKS ARE BAKERS  
YOUR REQUEST IS AMBIGUOUS TO ME, DO YOU WANT:  
1): CURRENT JOB TITLE = COOK & LAST NAME = BAKER.  
2): LAST NAME = COOK & CURRENT JOB TITLE = BARKER.  
PLEASE ENTER THE NUMBER OF THE INTERPRETATION YOU INTEND.  
-

---

**Figura 2.17. Ejemplo de sistema de lenguaje natural.**

**Fuente: [WEB10]**

### Los sistemas de percepción visual, audible y táctil

Pueden interpretar escenas plásticas o pueden inferir acerca de la calidad (ni roto ni doblado) u orientación física de los objetos que pasan por delante de una cámara de televisión.

Las capacidades de los sistemas de visión computarizada sólo se pueden utilizar bajo ciertas condiciones de iluminación y en escenarios simples. Tales condiciones se dan en los entornos fabriles. Allí, añadiendo capacidad visual a los sistemas robóticos, se elimina la necesidad de constante reprogramación y reajuste de los brazos de los robots que suelen desajustarse innecesariamente.

## Robótica

La Robótica es una ciencia que estudia el diseño y construcción de máquinas capaces de desempeñar tareas realizadas por el ser humano o que requieren del uso de inteligencia.

Objetivos de la robótica:

- El aumento de la productividad. Esto se consigue optimizando la velocidad del trabajo del robot, que reduce el tiempo parcial a cargo del manipulador y aumenta el rendimiento total en línea de producción.
- Ahorro en costos de mano de obra, menores pérdidas de material residual, pocas averías, mantenimiento reducido.
- Mejorar la calidad de los productos fabricados, dada la precisión en los movimientos del robot.
- Realizar trabajos en condiciones hostiles y peligrosas, por ejemplo en ambientes con temperaturas elevadas, con contaminación, entornos submarinos o espaciales, etc.

Campos de aplicación de la robótica:

- Investigación y exploración. En donde los robots presentan la ventaja de resistir los ambientes hostiles pare el ser humano.
- Entretenimiento. Recreación de situaciones ficticias, haciendo uso de efectos especiales.
- Construcción. Uso de robots para tareas de dimensionamiento, transporte, montaje, entre otras.
- Automatización industrial. Uso de robots a fin de mejorar, agilizar y aumentar la producción en los diferentes procesos.

## 2.5 Antecedentes

Existen trabajos relacionados al pronóstico de consumo de energía, así como también pronóstico de demandas aplicadas a otro tipo de sectores. Estos trabajos han sido desarrollados usando redes neuronales; por ejemplo:

**Cristian Foix y Richard Weber [FOX 1996]** usaron redes neuronales como herramienta para el pronóstico del precio anual del cobre. Los resultados conseguidos se contrastaron con los generados mediante la aplicación de los más tradicionales y exitosos modelos de series de tiempo.

Los investigadores evaluaron el desempeño predictivo de diferentes redes neuronales de tipo 'multilayer perceptron', construidas sobre la base del precio rezagado del cobre y variables derivadas del mismo, tales como la última variación del precio y la desviación estándar de los últimos periodos.

En las evaluaciones realizadas, los modelos no lineales de pronóstico, basados en redes neuronales 'multilayer perceptron', superaron la exactitud de los modelos lineales de series de tiempo más comúnmente usados. De esta manera, las redes neuronales demostraron ser capaces de aprovechar mejor la información contenida en los precios históricos considerados en el estudio.

La mayor exactitud de los pronósticos conseguidos utilizando redes neuronales va acompañada por una mayor complejidad en el diseño. En este estudio se optó por sensibilizar sólo algunos parámetros del diseño de una red y, aún así, el número de cálculos y el tiempo requerido fueron muy superiores al de los modelos de series de tiempo (horas versus minutos).

Si bien las redes neuronales superaron a los modelos de series de tiempo, los resultados conseguidos con la aplicación de modelos híbridos muestran que, mediante el trabajo conjunto con modelos de series de tiempo y redes neuronales, es posible conseguir pronósticos más precisos para el precio del cobre.

Las evidencias entregadas avalan a las redes neuronales como una herramienta atractiva para el pronóstico del precio del cobre, animando el desarrollo de futuros estudios que aporten más antecedentes sobre su potencial y motivando la investigación de metodologías de diseño que posibiliten el aprovechamiento de dicha capacidad de generalización.

Se concluye que las redes neuronales, aunque requieren un mayor esfuerzo en su diseño, pueden ser una herramienta valiosa para el pronóstico del precio del cobre.

**Sergio Nojek, Pedro Britos, Rodrigo García Martínez [NOJ 1997]** llevaron a cabo un estudio sobre la predicción de ventas mediante el uso de redes neuronales, comparando los resultados obtenidos con los pronósticos de un método estadístico clásico y estableciendo los entornos más adecuados para su uso.

Los resultados de esta investigación permitieron concluir con un nivel de confianza del 82.29 % que las redes neuronales realizaron un pronóstico más acertado en comparación al método estadístico utilizado. Este resultado corresponde al promedio de los mejores pronósticos para cada serie de tiempo

**Juan Camilo Santana [SAN 1998]** realizó una evaluación de la capacidad de las redes neuronales en la predicción de series temporales.

En esta investigación se evidencian las bondades de las redes neuronales en la predicción, comparadas con otras metodologías tradicionales. La idea principal del investigador es describir una metodología alternativa, referente al mecanismo de modelamiento de la red neuronal y diferente a la expuesta en investigaciones preliminares en el contexto colombiano, que permita unirse al abanico de técnicas ya existentes en esta línea.

El conocimiento de la inflación (información que es publicada mensualmente) resulta fundamental al tomar decisiones tanto de control sobre los instrumentos de política monetaria, como tasas de interés, encajes bancarios u operaciones de diversa índole que aumenten o contraigan la disponibilidad de recursos en la economía. Por ejemplo, para los mercados de capitales es fundamental contar con políticas de los bancos centrales enfocadas a mantener bajo control la inflación, en la medida en que se aminora la incertidumbre de los agentes, las tasas de interés pueden reducirse, y por ende, se estimula la actividad económica.

**Harold Salazar Isaza [SAL 2004]** presenta una aplicación de la teoría de redes neuronales en pronósticos de ventas.

El propósito de esta investigación es presentar una aplicación de la teoría de redes neuronales en pronósticos de producción mensuales basada en datos de ventas mensuales a fin de aumentar las alternativas y poniendo esta herramienta al alcance de grupos de apoyo y capacitación de PYMES.

El uso óptimo de los recursos, la creciente demanda de una mayor variedad de productos, entre otros, obliga a los fabricantes a realizar programas de producción más estrictos y flexibles para poder maximizar el uso de los costosos equipos de producción, mano de obra, inversiones en materias primas, de forma que se cumplan las fechas de entrega a los clientes finales minimizando los costos. Para realizar eficientes

programas de producción que atiendan la demanda sin incurrir en excesivos costos de capital, es deseable un adecuado manejo de la información de ventas con el fin de realizar pronósticos con buen nivel de confianza para todos los departamentos de la empresa.

Un pronóstico de ventas es una técnica que permite calcular las proyecciones de ventas de una manera rápida y confiable, utilizando como fuentes de datos, ya sea las transacciones de inventarios o la facturación de ventas realizadas. También permite estimar la demanda hacia el futuro, basándose en información histórica generada por el movimiento de productos del módulo de Control de Inventarios o por las ventas del módulo de facturación.

Para cumplir con el objetivo planteado y teniendo en cuenta que se trata de un fenómeno regido por el comportamiento de los meses anteriores (tendencia) se propone una red neuronal que sea alimentada con los niveles de ventas de períodos de tiempo anteriores al que se desea estimar y con un parámetro que informe el período que se desea estimar dado que el problema que se está abordando es de tipo estacional. Con toda esta información la red debe pronosticar un nivel de ventas partiendo del comportamiento histórico de dicha variable.

**Diego Raúl Cadavid [CAD 2006]** realiza un pronóstico del precio de la energía eléctrica usando redes neuronales artificiales.

Un elemento importante para los administradores de los mercados de la electricidad es el pronóstico de los precios en el corto, mediano y largo plazo. Decisiones sobre aumentos en la transmisión, expansión de la generación, planeación de la distribución e intercambios de electricidad entre regiones o países están determinadas por el pronóstico del precio de la electricidad en el largo plazo. Sin embargo, los niveles de transacciones entre los participantes del mercado dependen altamente del pronóstico del precio en el corto plazo.

En este trabajo se pretende estudiar el comportamiento del precio de la energía eléctrica en un rango de tiempo superior a los trabajos referenciados. Se propone un modelo basado en redes neuronales artificiales y se evalúa su desempeño en el pronóstico de un mes completo para el mercado eléctrico colombiano. Se utilizan dos estructuras de redes incluyendo como entradas la serie de precios diarios en la primera y la serie de precios más el nivel medio de los embalses en la segunda. Los resultados obtenidos se comparan con el pronóstico basado en un modelo *GARCH* encontrándose ventajas en este último dentro del período de muestreo, pero un mejor desempeño de las redes neuronales en el período fuera de la muestra.

**María Angélica Salazar Aguilar [SAL 2007]** describe la utilización de redes neuronales artificiales para pronóstico de demanda. Propone además un método para definir los parámetros de las RNAs de una manera integrada y repetible.

En este trabajo se propuso una metodología de selección de parámetros de un modelo de RNAs que utiliza técnicas establecidas y confiables y hace entendible la interrelación entre los varios parámetros de la RNA. Se demostró el funcionamiento de la metodología a través de un caso práctico, en el que se utilizaron modelos de RNA con múltiples salidas.

Los resultados de este trabajo apoyan la utilización de las RNAs como técnicas confiables de pronóstico y apuntan la factibilidad de su instauración en la industria.

A pesar de que son numerosas las aplicaciones desarrolladas mediante RNAs para pronóstico de series de tiempo y que los resultados han sido satisfactorios, no ha sido posible estandarizar una metodología que garantice la construcción de modelos de RNAs con buen desempeño, entendiendo “desempeño” como la exactitud del pronóstico. Por esta

razón se propone una metodología con base en estadística y optimización matemática que permite seleccionar de manera adecuada los parámetros del modelo.

**Arturo Jesús Vásquez Aguilar [GAL 2004]** presenta una investigación sobre el pronóstico de la demanda de bienes usando redes neuronales.

Una de las necesidades de las empresas comercializadoras y las industriales es calcular un pronóstico de las ventas de sus productos a corto, mediano y largo plazo; pero son más urgentes y por lo tanto de mayor preocupación los resultados que se quieren en un horizonte de tiempo cada vez más pequeño; es decir para el día, semana y a lo más el mes siguiente para poder iniciar la planificación de las actividades de otras involucradas en el proceso de producción y ventas.

Esta investigación tiene como finalidad construir un modelo de red neuronal para pronosticar la demanda de los productos de una empresa industrial o comercializadora dado que ellos necesitan estos resultados para poder planificar sus actividades en otras áreas tales como: Marketing, Producción, Finanzas, etc.; para este caso los resultados se presentan en un horizonte de pronóstico a corto plazo de máximo 1 mes; a su vez si se llega a demostrar la hipótesis que el modelo pronostica con error mínimo menor al 1% se pretende como trabajo futuro ampliar el horizonte a 6 meses y 1 año y así sucesivamente en forma gradual e iterativa.

La característica primordial de este modelo es que debe aprender patrones de comportamiento del cliente en ciertas fechas tomando como base las ventas históricas y las variaciones en el nivel de precios del producto.

## 2.6 Metodologías para la predicción

### 2.6.1 Lógica difusa [WEB15]

La teoría de *lógica borrosa* fue introducida por Loffi A. Zadeh, a mediados de los años 60 (*Fuzzy Sets*), y desde esa fecha se ha desarrollado como una herramienta elemental para el control de subsistemas y procesos industriales complejos, ya que los sistemas borrosos permiten modelar sistemas no lineales, y aprender de los datos haciendo uso de determinados algoritmos de aprendizaje. La *lógica borrosa* surge como un perfeccionamiento de la *lógica booleana* tradicional, en la cual los conjuntos son considerados como sistemas bivalentes, con sus estados alternando entre “pertenencia” o “no pertenencia” (inclusión o exclusión), donde tradicionalmente se define la función característica,  $f_A$  – que describe la pertenencia de un elemento  $x$  al conjunto  $A$  –, como:

$$f_A = \begin{cases} 1 & \text{si } x \in A \\ 0 & \text{si } x \notin A \end{cases}$$

De esta forma, la pertenencia de un elemento al conjunto  $A$  queda fraccionada y las relaciones entre conjuntos quedan categorizadas, siendo la transición entre dos conjuntos (o estados)  $A$  y  $B$  radical e inmediata.

La *lógica borrosa*, por su parte, considera la idea de variable lingüística, que capta las propiedades de aproximación o los conceptos de imprecisión en un sistema, permitiendo que un elemento tenga valores intermedios en el grado de pertenencia a un conjunto determinado. Cada elemento del universo tiene asociado una función de pertenencia continua  $f_A$  – que toma valores entre 0 y 1 – que indica el “grado de pertenencia” del elemento  $x$  al conjunto  $A$ .

Así, un conjunto en el universo de discurso  $U$  es definido por una función de pertenencia  $f_A: U \rightarrow [0, 1]$ , donde  $f_A(x) \in [0,1]$  indica el grado de pertenencia de  $x$  al conjunto  $A$ .

Bajo este concepto de *lógica borrosa* reside la idea que los elementos claves del pensamiento no son numéricos, sino que son ideas con cierto grado de vaguedad, donde los elementos pasan de un conjunto a otro de manera suave y flexible, convirtiéndose de esta forma en una herramienta atractiva para manejar la incertidumbre.

La *lógica borrosa* incorpora tres pasos fundamentales: (1) la elección de los *inputs* del proceso *fuzzy*, (2) la designación de funciones y conjuntos de pertenencia y, (3) la determinación de las *reglas difusas* y de la variable de salida (*defuzificación*).

Los *input* del proceso *fuzzy* se refieren a las variables que se presumen importantes de considerar, ya que el comportamiento de éstas y sus combinaciones influyen sobre la variable que se desea proyectar. Estas variables son agrupadas en los *conjuntos de pertenencia* al cual pertenecerán en algún grado.

Los *conjuntos difusos* son determinados por sus *funciones de pertenencia*. Comúnmente, el número de conjuntos difusos es definido de manera tal que contenga todo el rango de posibles valores que podría adoptar la variable. Este rango de variación es conocido como *universo de discurso*. Las *funciones de pertenencia* generalmente son funciones continuas cuyo dominio es el *conjunto de discurso* y su *imagen* un valor real entre 0 y 1, el cual representará el grado de pertenencia de la variable al *conjunto difuso* en cuestión. Estos conjuntos de pertenencia, junto a las *reglas difusas*, determinarán el comportamiento que tendrá la variable de salida.

Las operaciones con conjuntos requieren el establecimiento de reglas para combinar los *conjuntos de pertenencia* y los conjuntos de unión,

intersección y complemento. Estas operaciones entre conjuntos se asociarían a las conexiones lingüísticas “y”/“o”. Así, la intersección se asocia a “y”, mientras que la unión a “o”. De esta manera se pueden conectar y manipular los conjuntos para, a su vez, obtener nuevos conjuntos de pertenencia. En principio, no existen reglas generales o un método de construcción de *reglas fuzzy* o de funciones de pertenencia, por lo que éstas son determinadas por cada diseñador. No obstante, éstas deben cumplir con las propiedades de *t-normas* para la intersección y *t-conormas* para la unión.

El proceso de proyección es realizado por medio de la elaboración de *reglas difusas*, las cuales relacionan la correspondencia entre los *input* y el *output* a través de las operaciones de conjuntos. La forma usual de las *reglas difusas* es del tipo: *si  $i_1$  es  $f_1$  y/o  $i_2$  es  $f_2$  y/o...  $i_n$  es  $f_n$ , entonces  $o_t$  es  $o_k$* . Donde  $i_1, i_2, \dots, i_n$  son los *inputs* atribuibles a las funciones de pertenencias  $f_1, f_2, \dots, f_n$ , respectivamente;  $o_t$  es el *output*; y  $o_k$  es la clasificación atribuible a  $o_t$ . Finalmente, el *output fuzzy* debe ser transformado en una variable posible de interpretar, proceso denominado *desfuzificación*. [WEB15]

Entre las ventajas que ofrecen los sistemas de lógica difusa tenemos:

- La posibilidad de los sistemas de inferencia difusa de integrar la irremplazable experiencia de expertos humanos. Esta experiencia se puede implementar fácilmente en las reglas del tipo “SI.....ENTONCES....”.
- Los sistemas de inferencia difusa pueden integrar términos lingüísticos en el razonamiento (conjuntos difusos para algunas de las variables).

Sin embargo los sistemas de inferencia difusa presentan limitaciones: desde el principio se deben fijar las reglas que establecen el funcionamiento del sistema; y en ocasiones, un cambio de

condiciones puede requerir la creación de un nuevo sistema de inferencia difusa (puede aparecer una imposibilidad en adaptar el sistema al cambio de condiciones).

### **2.6.2 Redes Neuronales Artificiales [WEB16]**

Con un paradigma convencional de programación en ingeniería del software, el objetivo del programador es modelar matemáticamente (con distintos grados de formalismo) el problema en cuestión y posteriormente formular una solución (programa) mediante un algoritmo codificado que *tenga* una serie de propiedades que permitan resolver dicho problema. En contraposición, la aproximación basada en las RNA parte de un conjunto de datos de entrada suficientemente significativo y el objetivo es conseguir que la red *aprenda* automáticamente las propiedades deseadas. En este sentido, el diseño de la red tiene menos que ver con cuestiones como los flujos de datos y la detección de condiciones, y más que ver con cuestiones tales como la selección del modelo de red, la de las variables a incorporar y el preprocesamiento de la información que formará el *conjunto de entrenamiento*. Asimismo, el proceso por el que los parámetros de la red se adecúan a la resolución de cada problema no se denomina genéricamente programación sino que se suele denominar *entrenamiento neuronal*. [WEB14]

De los distintos tipos de redes neuronales, el perceptrón multicapa es el que ha demostrado más efectividad en distintos tipos de aplicaciones, es por esto que lo pondremos como ejemplo para demostrar la metodología a usar al construir una red neuronal:

El Perceptrón consiste en un tipo de Red Neuronal con varias capas, donde cada neurona de una capa se conecta con todas las de la siguiente. En la definición de la topología surge originalmente la

interrogante de cuantas capas utilizar. Al respecto, muchos autores consideran que para el 90% de los problemas son suficientes tres capas (llamadas capa de entrada, capa oculta y capa de salida), y puede comprobarse que se obtienen muy buenos niveles de precisión en diferentes dominios de datos, por lo que es conveniente comenzar con dicho número de capas y anexar una capa más solo si los resultados primarios no son satisfactorios. Hay registro de casos excepcionales que han requerido cuatro capas, y en general no se suelen implementar Perceptrones con más niveles que estos.[WEB16]

Una vez determinado el número de capas, se procede a determinar el número de neuronas que contendrá cada capa. La cantidad de neuronas en la capa de entrada viene determinada por el propio Dominio de Datos, debiéndose definir un mecanismo de representación numérica de los datos lo que constituye un momento clave en el diseño. A modo de ejemplo, para el caso de reconocimiento de diseños gráficos tales como letras o números, se suele tomar como entrada una matriz de pixeles o retina, donde cada uno representa un valor booleano (0 o 1) según haya o no un pixel en la coordenada en cuestión, de modo que en este caso la traducción del dominio de datos a una expresión numérica es directa, sin embargo existen dominios de datos donde definir la representación numérica adecuada no es tarea sencilla.

Otro problema surge en muchos casos, donde la complejidad del dominio de estudio es tal que no es claro que entradas deben tomarse. En estos casos, es importante limitar las entradas a los aspectos más relevantes. Gran número de entradas e interconexiones no garantizan mayor precisión de la red, por el contrario, el introducir variables poco relevantes introduce "ruido" en la red, haciendo más lenta la convergencia y a veces, incluso imposible. Si se dispone de juegos de datos demasiado abundantes, una opción es clusterizar variables reduciendo el numero de entradas por procedimientos estadísticos, asumiendo con todo, que cierta información que tiene

que ver con el modo en que se combinan las variables "crudas" se pierde en el propio proceso de clusterización, como solución de compromiso para mantener un vector de entrada razonablemente simple.

En el otro extremo, la capa de salida viene determinada por el resultado que se pretende extraer de la Red Neuronal, a partir de las variables de entrada, pero pueden mencionarse algunas recomendaciones a modo de heurísticas para determinar su número. Una es mantener el criterio de no anexar neuronas adicionales sin una justificación razonable, en muchos casos bastará una neurona en la capa de salida, dependiendo de la naturaleza del problema. Por ejemplo, si la salida debe ser una respuesta afirmativa o negativa (tal como ocurre en análisis de mercado para recomendación de inversiones, identificación de huellas digitales; etc.) bastará una neurona, con un resultado booleano 0 o 1. En todos los casos, una red neuronal trata de resolver el problema de una relación entre determinadas entradas y una salida que de alguna manera es función de estas. Dicha función no es conocida por nosotros, o tal vez no es posible hallar una expresión matemática (que sería lo óptimo, permitiendo entonces una solución algorítmica) o bien la misma es demasiado compleja e inmanejable, o es dinámica, variando en el tiempo, de modo que no nos es útil una expresión estática de la misma en un momento dado. Algunos dominios son funcionales, y en estos casos la red intenta aproximar la función. Cuando la función buscada es monótona, por lo que es fácilmente interpolable, una sola neurona en la capa de salida será suficiente obteniéndose un valor real entre 0 y 1 al que luego puede aplicarse un parámetro para obtener la salida deseada.

El mayor desafío consiste en realidad en determinar cuantas neuronas incluir en la capa intermedia o "capa oculta" .Con todo, pueden considerarse principios generales: es conveniente que sean menos que las de la capa de entrada, porque en esta capa intermedia

se "condensa" la información, la experiencia muestra que un número excesivo de neuronas genera confusión y enlentece la convergencia, y en el mejor de los casos facilita la memorización en detrimento de la inferencia, un efecto rara vez deseable.

Es cada vez más común el utilizar técnicas mixtas, como por ejemplo, algoritmos para prueba y selección de estructuras, o procedimientos estadísticos con la misma finalidad. Una innovación interesante, en este campo de técnicas mixtas es la de aplicar Algoritmos Genéticos tanto en la determinación del número de neuronas de capa oculta, como también el número de interconexiones (Angeline, J., 1993).

Dichos algoritmos son en general de convergencia lenta, aunque una vez obtenida la estructura, pueden aplicarse los procedimientos de entrenamiento usuales. En todo caso, deberá considerarse que en tal caso, el procedimiento será solo adecuado para dominios estables, y no siempre es claro si el aumento en la complejidad algorítmica compensa en términos de una mayor convergencia o si esto no puede lograrse por otros medios como afinar los procedimientos de entrenamiento de la red.

## **ENTRENAMIENTO**

Diversos algoritmos se han ensayado en las redes multi-capas: de premiación y penalización, aumentando los pesos de las neuronas que arriban a la solución esperada, penalizando las otras, por competencia, donde se establecen conexiones laterales dentro de la capa, y donde la neurona que se activa inhibe a las otras, y algoritmos de minimización de la función de error, particularmente el BackPropagation, también llamado del Gradiente descendente, que en general es superior a otros métodos, en términos de velocidad de convergencia, porque además, no aplica un ajuste arbitrario sino que tiene un fuerte fundamento matemático, que es el de determinar el

error de las variables a partir del error funcional, mediante calcular el gradiente (ya que la "función" es de argumento vectorial) como es un conocido procedimiento de Calculo Numérico.

### **VALIDACION**

En general se recomienda utilizar un 80% de los datos disponibles para el entrenamiento y el 20% restante para la validación. En general es deseable que el set de datos sea lo suficientemente grande para que esto de resultado, tanto en el numero de registros como en el numero de variables.

Otra experimentación interesante es generar perturbación en las variables para medir su incidencia relativa en el resultado global, lo que puede permitir identificar problemas de condicionamiento y que pueden involucrar revisar si la selección de variables es la adecuada.

### **2.6.3 Data Mining [WEB8]**

Datamining(minería de datos), es el conjunto de técnicas y tecnologías que permiten explorar grandes bases de datos, de manera automática o semiautomática, con el objetivo de encontrar patrones repetitivos, tendencias o reglas que expliquen el comportamiento de los datos en un determinado contexto.

Datamining surge para intentar ayudar a comprender el contenido de un repositorio de datos. Con este fin, hace uso de las ventajas de varias áreas como la Estadística, la Inteligencia Artificial, la Computación Gráfica, las Bases de Datos y el Procesamiento Masivo, principalmente usando como materia prima las bases de datos.

### Metas de la minería de datos:

- **Análisis exploratorio de datos:** La meta es simplemente explorar los datos sin una idea clara de lo que estamos buscando.
- **Modelado descriptivo:** La idea principal es describir todos los datos, normalmente es usada para análisis preliminar de los datos (resumen, características de los datos, casos extremos, etc).
- **Modelado predictivo, regresión y clasificación:** El objetivo es construir un modelo que permita que el valor de una variable sea predecido mediante el conocimiento de las otras. En clasificación la variable a predecir es categórica, mientras que en regresión es cuantitativa.
- **Descubrimiento de patrones y reglas:** Su misión es la detección de patrones que ocurren en los datos.
- **Retroalimentación por el contexto:** Aquí el usuario tiene un patrón en específico y quiere buscar patrones similares en el conjunto de datos.

### Etapas de la minería de datos:

- **Determinación de los objetivos.** Trata de la delimitación de los objetivos que el cliente desea bajo la orientación del especialista en datamining.
- **Preprocesamiento de los datos.** Se refiere a la selección, la limpieza, el enriquecimiento, la reducción y la transformación de las bases de datos. Esta etapa consume generalmente alrededor del setenta por ciento del tiempo total de un proyecto de datamining.
- **Determinación del modelo.** Se comienza realizando unos análisis estadísticos de los datos, y después se lleva a cabo una visualización gráfica de los mismos para tener una primera

aproximación. Según los objetivos planteados y la tarea que debe llevarse a cabo, pueden utilizarse algoritmos desarrollados en diferentes áreas de la Inteligencia Artificial.

- Análisis de los resultados. Verifica si los resultados obtenidos son coherentes y los coteja con los obtenidos por los análisis estadísticos y de visualización gráfica. El cliente determina si son novedosos y si le aportan un nuevo conocimiento que le permita considerar sus decisiones.

Técnicas de minería de datos:

- Redes neuronales: Son un paradigma de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso de los animales. Se trata de un sistema de interconexión de neuronas en una red que colabora para producir un estímulo de salida.
- Regresión lineal: Es la más utilizada para formar relaciones entre datos. Rápida y eficaz pero insuficiente en espacios multidimensionales donde puedan relacionarse más de 2 variables.
- Árboles de decisión: Un árbol de decisión es un modelo de predicción utilizado en el ámbito de la inteligencia artificial, dada una base de datos se construyen estos diagramas de construcciones lógicas, muy similares a los sistemas de predicción basados en reglas, que sirven para representar y categorizar una serie de condiciones que suceden de forma sucesiva, para la resolución de un problema.
- Modelos estadísticos: Es una expresión simbólica en forma de igualdad o ecuación que se emplea en todos los diseños experimentales y en la regresión para indicar los diferentes factores que modifican la variable de respuesta.
- Agrupamiento o Clustering: Es un procedimiento de agrupación de una serie de vectores según criterios habitualmente de

distancia; se tratará de disponer los vectores de entrada de forma que estén más cercanos aquellos que tengan características comunes.

Ejemplos de uso de minería de datos:

- Negocios: En lugar de contactar con el cliente de forma indiscriminada a través de un centro de llamadas o enviando cartas, sólo se contactará con aquellos que se perciba que tienen una mayor probabilidad de responder positivamente a una determinada oferta o promoción.
- Hábitos de compras: Un estudio muy citado detectó que los viernes había una cantidad inusualmente elevada de clientes que adquirirían a la vez pañales y cerveza. Se detectó que se debía a que dicho día solían acudir al supermercado padres jóvenes cuya perspectiva para el fin de semana consistía en quedarse en casa cuidando de su hijo y viendo la televisión con una cerveza en la mano. El supermercado pudo incrementar sus ventas de cerveza colocándolas próximas a los pañales para fomentar las ventas compulsivas.
- Fraudes: Generalmente las operaciones fraudulentas o ilegales suelen seguir patrones característicos que permiten, con cierto grado de probabilidad, distinguirlas de las legítimas y desarrollar así mecanismos para tomar medidas rápidas frente a ellas.
- Comportamiento en Internet: La utilización de la información (obtenida por medios más o menos legítimos) sobre los clientes potenciales para ofrecerles propaganda adaptada específicamente a su perfil. O para, una vez que adquieren un determinado producto, saber inmediatamente qué otro ofrecerle teniendo en cuenta la información histórica disponible acerca de los clientes que han comprado el mismo producto.

#### **2.6.4 Elección de la metodología a utilizar**

De las metodologías presentadas hemos decidido utilizar la de redes neuronales artificiales puesto que presenta varias ventajas tales como su capacidad de aprendizaje, tolerancia a fallos, autoorganización y flexibilidad; y si bien las redes neuronales tienen como desventaja la necesidad de disponer de gran cantidad de datos para su entrenamiento, creemos posible que en nuestro caso podemos subsanar este inconveniente debido a la disponibilidad que tenemos de los datos necesarios para entrenar nuestra red.

Si bien los sistemas de lógica difusa también podrían usarse para problemas de predicción donde se tengan que utilizar funciones no lineales que son propias de la demanda eléctrica (y en donde los modelos estadísticos tradicionales no podrían aplicarse), estos tendrían como principal inconveniente que desde el principio se deben fijar las reglas que establecen el funcionamiento del sistema y si se da un cambio de condiciones se puede requerir la creación de un nuevo sistema de inferencia difusa.

Por otro lado, el uso de datamining, se encuentra orientado al descubrimiento de conocimiento en las bases de datos, que puede ser útil para algún proceso dentro de la organización y que ayuden a la toma de decisiones. Es por ello que antes de analizar la data, se realizan pasos previos, como la selección, reducción y transformación de las bases de datos (que consumen bastante tiempo), para trabajar únicamente con data relevante de acuerdo a los objetivos que se desean obtener.

Y en nuestro caso, para el pronóstico de consumo de electricidad, no es necesario llevar a cabo este análisis previo; sino, procesar la cantidad necesaria de información para poder generar un modelo más consistente que pueda realizar el pronóstico de manera más fiable.

# **CAPÍTULO III:** **ARQUITECTURA DE LA RED** **NEURONAL**

Quizás la parte más difícil en la construcción de un buen modelo de red neuronal es la relacionada con selección y recolección de la información que alimentará al mismo en la fase de entrenamiento. Una serie de investigaciones realizadas sobre la demanda eléctrica y sus determinantes (P.Murto (1998), J.Bao (1996), Proyecto Indel (1998)) en diferentes países, han permitido identificar un conjunto de variables básicas que explica la evolución de la demanda eléctrica a lo largo del tiempo, siendo este conjunto común para la mayor parte de los países desarrollados. De este modo para modelizar la curva de carga de países tan distintos como España y Estados Unidos utilizaríamos el mismo conjunto de variables causa.

### **3.1 Variables que intervienen en la red neuronal**

#### **3.1.1 Condiciones meteorológicas**

Aquí englobaríamos variables como la velocidad del viento, la nubosidad, la pluviosidad, la temperatura, etc. Sin embargo nos encontramos con que no todos los factores climáticos afectan a la demanda eléctrica. Algunos de ellos son típicamente aleatorios y otros aparecen interrelacionados. Por ejemplo, la temperatura viene explicada parcialmente por la nubosidad, la pluviometría, la humedad relativa, etc.

Entre todos estos factores la temperatura es el más relevante, dado que influye de forma directa sobre múltiples fuentes de consumo eléctrico como sistemas calefactores, aire acondicionado, refrigeradores, etc. Esta relación entre la demanda eléctrica y la temperatura es de carácter no lineal.

En nuestro modelo incluiremos dos variables climáticas: la temperatura y la humedad. La temperatura, dado que es una variable meteorológica determinante en la demanda eléctrica; en cuanto a la humedad, para contar con otra variable climática para un mejor pronóstico del consumo para el presente trabajo.

### 3.1.2 Calendario

Existen diferentes efectos relacionados con el calendario que inciden sobre la curva de demanda eléctrica:

- **Hora del Día:** Es una de las variables más importantes que afectan a la curva de la demanda, resulta evidente que la demanda eléctrica realizada a las tres de la madrugada no será igual a la realizada a las tres de la tarde.

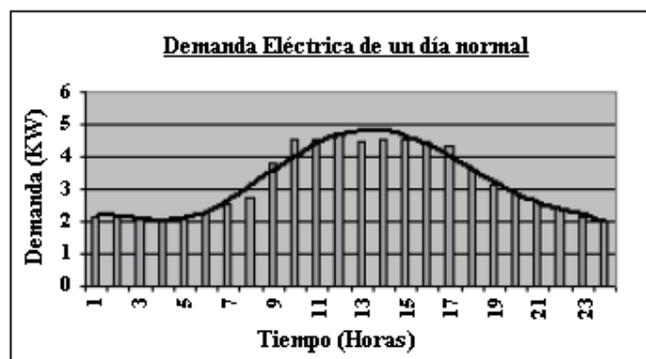


Figura 3.1. Curva de la demanda.

Fuente: [WEB9]

En la figura 3.1 se puede apreciar como el grueso de la demanda eléctrica se acumula en el período comprendido entre las 9 de la mañana y las cinco de la tarde, algo lógico si tenemos en cuenta que dicho período se corresponde con la

jornada laboral estándar. Para que nuestro modelo sea capaz de reflejar este efecto debemos incluir una variable que represente la hora del día en la que se lleva a cabo la demanda. Para ello utilizaremos una variable numérica cuyo rango oscilará entre 0 y 23. [0, 1,2...22,23].

- **Día de la semana:** Repitiendo el mismo planteamiento podemos intuir que la demanda de electricidad realizada a la misma hora de días diferentes será también diferente. Así la demanda llevada a cabo un miércoles a las once de la mañana probablemente no coincida con la realizada un domingo a esa misma hora.

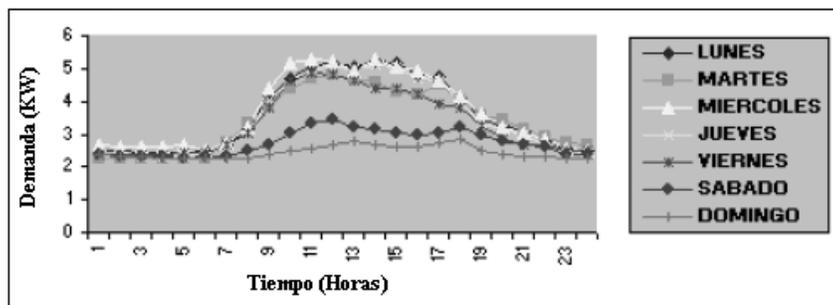


Figura 3.2. Curva de la demanda según los días de la semana.

Fuente: [WEB9]

En la figura 3.2 se puede apreciar como todos los días laborables poseen un perfil de demanda muy similar, con excepción del lunes y el miércoles en cuyas madrugadas el consumo de energía es significativamente inferior. Con respecto a los fines de semana se observa como si bien se repite el mismo patrón horario de consumo detectado en los días laborables, en general el consumo medio es sensiblemente inferior. Para que el modelo sea capaz de identificar el perfil de la demanda asociada a cada día de la

semana debemos de incluir una variable que recoja este efecto. Esta variable será categórica y estará codificada de la siguiente manera: Lunes=0...Domingo=6

- **Fin de semana y feriados** Teniendo en cuenta las conclusiones a las que llegamos al estudiar el gráfico, podemos observar la presencia de un factor que incide sobre la demanda eléctrica y que está asociado a los fines de semana y a los días no laborables.

En estos días se produce una reducción generalizada en el consumo eléctrico. Este nuevo factor puede ser incluido en nuestro modelo mediante una variable dicotómica que tome el valor 0 si la demanda se realiza en un día laborable, ó 1 en otro caso.

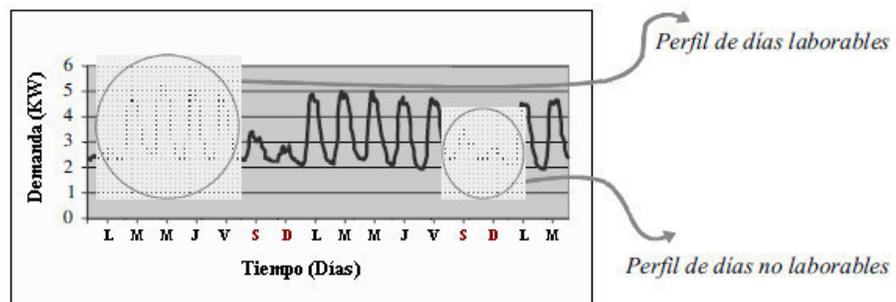


Figura 3.3. Curva de la demanda a lo largo de la semana.

Fuente: [WEB9]

- **Mes del año:** En función del mes en el que nos encontremos la demanda diaria media de energía varía significativamente. Esto se debe principalmente al efecto de las estaciones. Pensemos que en los meses de invierno, al margen de los efectos climáticos ya considerados (básicamente temperatura), se dispone de un menor número de horas solares, la gente tiende

a pasar más tiempo en casa, etc. En lo referente al verano el consumo de energía también puede experimentar un considerable aumento como resultado del uso de sistemas de aire acondicionado. Atendiendo a la figura 3.4 podemos comprobar como efectivamente la curva de la demanda anual alcanza sus valores máximos en los meses de verano e invierno. Por tanto debemos de incluir en nuestro modelo una variable que recoja esta *componente estacional* de la demanda eléctrica.

Para ello utilizaremos una variable categórica cuyos valores representarán los distintos meses del año. Esta variable será codificada, asignándole valores que irán desde el Enero = 0, hasta el Diciembre = 11.

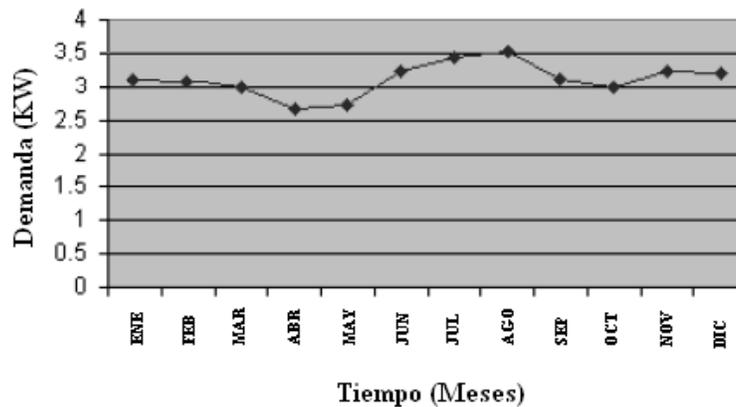


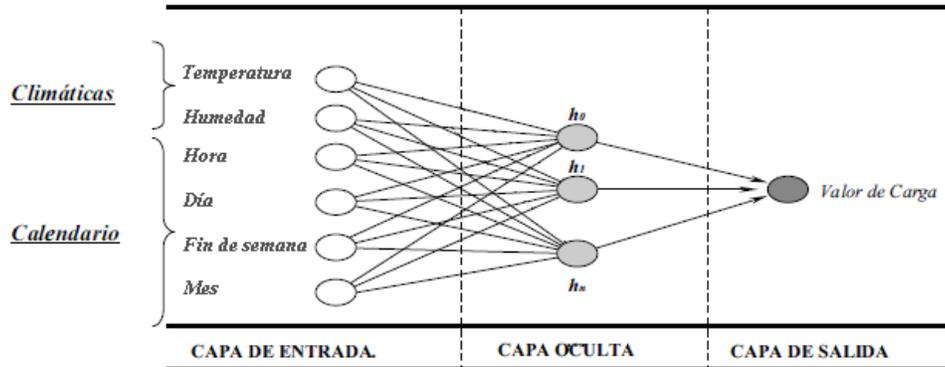
Figura 3.4. Curva de la demanda anual.

Fuente: [WEB9]

### 3.2 Modelo neuronal de la demanda

La red que proponemos estará compuesta por tres capas: Una de entrada, una oculta y una de salida. En lo referente a la capa de entrada, ubicaremos en la misma seis unidades que representarán cada uno de

los factores explicativos seleccionados. La capa de salida solo contará con una unidad, la cual indicará el valor de la carga eléctrica horaria asociado a cada vector de inputs presentado a la red. Finalmente la capa oculta contará con un número variable de neuronas. Esquemáticamente nuestro modelo de red neuronal artificial tendría la siguiente forma:



**Figura 3.5. Representación esquemática de la RNA empleada.**

**Fuente: Elaboración propia**

La determinación del número óptimo de neuronas de la capa oculta se llevará a cabo mediante un proceso de ensayo y error en el que jugamos con el número de neuronas. Finalmente, luego de realizar el entrenamiento con diferentes números de neuronas en la capa oculta (2,3 y 4), decidimos que tres neuronas en la capa oculta sería lo más adecuado para nuestro modelo. En todo caso, nuestro objetivo será dotar a la red de un número adecuado de neuronas en la capa oculta para que sea capaz de aprender las características de las posibles relaciones existentes entre los datos de la muestra.

Demasiadas neuronas podrían llevarnos a un sobre-ajuste, la red memorizaría el conjunto de datos de entrenamiento y para valores pertenecientes al mismo su precisión sería casi absoluta. Sin embargo si le presentamos valores desconocidos fallaría estrepitosamente, dado que como consecuencia del sobre-ajuste sería incapaz de generalizar. Por

otra parte si el número de neuronas en la capa oculta es reducido podremos llegar a una situación de sub-ajuste, en la cual la red no sería capaz de aprender ciertas relaciones existentes entre las variables. Aprovechando las propiedades atribuidas a las RNA Unidireccionales (Teorema de Hornik-Stinchcombe-White, Hornik et al., (1990)), nuestro objetivo será aproximar la curva de la demanda, dado el conjunto de datos disponible, para posteriormente poder realizar predicciones sobre valores futuros.

### Datos de entrada

Teniendo en cuenta lo explicado anteriormente alimentaremos el modelo con la información aportada por las siguientes variables:

CATEGORIA	VARIABLE	UNIDADES	TIPO
CLIMATICAS	Temperatura	F°	Numérica Representada por su valor actual
	Humedad	%	Numérica Representada por su valor actual
CALENDARIO	Hora	-	Numérica. Representada por su valor actual Rango = (0-23)
	Día	-	Catagórica. Codificada : Lunes = 0, Martes = 1, ....., Domingo = 6
	Fin de semana	-	Numérica binaria. Fin de semana ó festivo = 0 /Día laborable = 1
	Mes	-	Catagórica. Codificada : Enero = 0, Febrero = 1, ....., Diciembre = 11
OBJETIVO	Demanda	KW	Numérica Representada por su valor actual

Tabla 3.1. Datos de entrada.

### **3.3 Justificación del tipo de red**

El algoritmo Backpropagation es un algoritmo de aprendizaje supervisado, el cual necesita conocer cuál es la salida esperada asociada a cada una de las entradas , que actualiza pesos y ganancias siguiendo la regla de pasos descendientes.

Una de las mayores ventajas de las redes multicapa, y en especial de la red Backpropagation, es que pueden aproximar cualquier función si se escoge una adecuada configuración para la red y un adecuado número de neuronas en la capa oculta, escogencia que depende de la experiencia del desarrollador de la red. La red backpropagation es un excelente aproximador de funciones, aunque es imposible determinar una configuración exacta de la red para cada aplicación.

El proceso de aprendizaje no es fijo para ninguna red neuronal, el éxito consiste en probar con diferentes configuraciones hasta obtener la respuesta deseada.

La elección de los patrones de entrada debe realizarse dependiendo de las necesidades explícitas que se tengan en el momento de hacer la predicción de carga, de la forma en que vaya a procesarse la información de salida de la red y de la cantidad y calidad de la información disponible.

Cualquier cambio que se realice en los patrones de entrenamiento exige una codificación diferente del vector de entrada y a su vez cambia las condiciones generales de la red, pero el proceso de entrenamiento sigue siendo igual.

### 3.4 Construcción de la red neuronal

Existen diversas herramientas gráficas para el entrenamiento de redes neuronales, que implementan algunos de los algoritmos existentes más comunes; entre ellas tenemos:

- NeuroSolutions
- JavaNNS
- Tiberius

Sin embargo debido a que la plataforma en la que se realizará el proyecto es web, no es necesario usar una herramienta que tenga su propia interfase; sino mas bien, una herramienta que permita el procesamiento de la información y devuelva el resultado al aplicativo web y que éste muestre el resultado al usuario a través de una página web.

MATLAB es un software matemático, conocido por su gran prestación en la manipulación de matrices, sus cálculos matemáticos, y la visualización gráfica de los mismos de una manera muy sencilla.

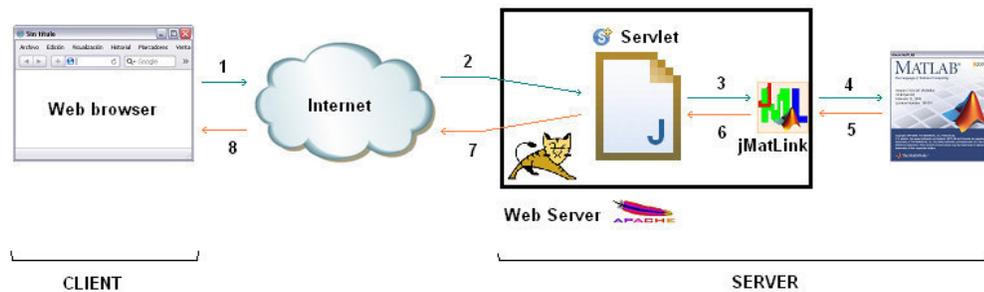
Las funcionalidades de MATLAB se agrupan en ToolBoxes (cajas de herramientas), siendo el 'nnTool' (Neural Network ToolBox), su interfaz para la manipulación de redes neuronales de manera visual.

Sin embargo también se pueden ejecutar los comandos en la consola para crear una red neuronal, entrenarla y simular un resultado; sin la necesidad de ejecutar el nnTool. Así, podriamos usar MATLAB para la manipulación de nuestra red neuronal.

Para poder ejecutar comandos de MATLAB desde el lenguaje de programación Java, MATLAB no ofrece ningún medio de comunicación oficial entre estos dos lenguajes. Sin embargo, existe una librería en java 'JMatLink', la cual nos permite a través de java, mandar comandos a una

instancia de MATLAB, obtener los resultados de la ejecución de dicho comando y guardar el resultado en una variable java.

En la siguiente figura, se puede observar cómo es que se lleva a cabo la comunicación entre las tecnologías involucradas en el desarrollo de esta aplicación.



**Figura 3.6. Representación de la comunicación entre las tecnologías.**  
**Fuente: Elaboración propia**

### 3.5 Implementación de una red neuronal en MATLAB

Matlab ya trae consigo funciones de redes neuronales en su Neural Network Toolbox e incluso cuenta con una interfaz gráfica que facilita ampliamente el diseño de redes neuronales. Esta interfaz gráfica permite diseñar redes, visualizarlas, entrenarlas, simularlas, entre otras opciones, sólo hay que definir los patterns (inputs/targets) , la red (número de entradas/salidas, capas ocultas y número de neuronas por capa) , y cambiar a nuestra conveniencia algunos parámetros que trae por *default* para cada tipo de red.

Mediante la inclusión de un amplio abanico de funciones y procedimientos escritos para Matlab , el usuario puede mediante el

Neural Network Toolbox efectuar el diseño de arquitecturas complejas , combinando los modelos que ya están proporcionados por defecto en el toolbox. Asimismo, el usuario puede definir sus propias funciones de transferencia e inicialización, reglas de aprendizaje, funciones de entrenamiento y estimación de error para usarlas posteriormente con las funciones básicas.

Dentro de las aplicaciones básicas de este toolbox , cabe destacar aquellas que están orientadas dentro de la industria aeroespacial ( simulación, sistemas de control ), banca, defensa (reconocimiento de patrones, procesamiento de señales, identificación de imágenes, extracción de características ) , electrónica ( control de procesos, identificación en tiempo real, sistemas de inspección ), medicina, robótica ( control de trayectorias, sistemas de visión ) , reconocimiento y síntesis del habla, telecomunicaciones ( control de datos e imágenes, servicios de información automatizada, etc).

Los siguientes son algunos de los comandos utilizados en la creación de una red neuronal:

- **Newff:** Crea una red tipo Backpropagation , requiere que le sean especificados los siguientes parámetros:

*newff:* (PR,[S1 S2...SNI])

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

Si: Número de neuronas para cada una de las capas

- **Train:** Una vez creada la red, el siguiente paso es realizar el entrenamiento con los patrones de entrada y las salidas deseadas. En cada ciclo de entrenamiento se recalculan los pesos de la red

tras presentar los patrones de entrenamiento. Requiere que le sean especificados los siguientes parámetros:

```
[net,TR,Y,E] = train(NET,P,T)
```

Los parámetros de entrada son:

NET: Una red inicializada

P: Los patrones de entrada

T: Las salidas deseadas

Y los parámetros de salida son:

net: Red entrenada

TR: Error en función de la iteración

Y: Salida de la red

E: Errores de la red

- **Sim:** Tras la fase de entrenamiento, la red está lista para ser usada, es decir, la red es capaz de producir una salida adecuada a un conjunto de patrones de entrada. La función `sim` es la encargada de pasar un conjunto de patrones de entrada a la red y de obtener su salida:

```
Y = sim (NET,P)
```

Donde:

NET: representa una red entrenada

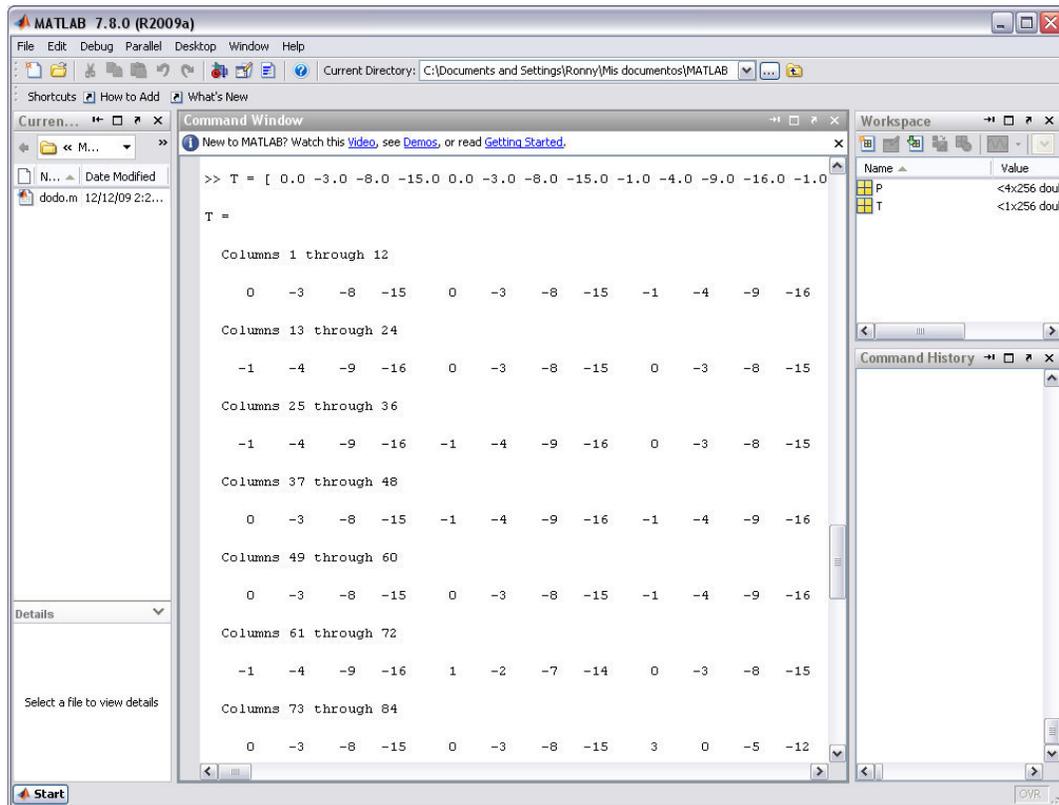
P: es el conjunto de patrones de entrada

Y: es la salida de la red

A continuación se muestra un ejemplo básico de cómo se utilizan los comandos básicos de MATLAB para la construcción de una red neuronal:



2. Se debe de crear un vector que contenga los valores esperados para las entradas ingresadas en el paso 1. Deber contar con la misma cantidad de registros que la matriz de entrada.



**Figura 3.8. Vector con entradas.**

**Fuente: Elaboración propia**

3. Se procede a crear la red neuronal, asignándole como atributos, la matriz de entrada, el vector con los resultados esperados, el número de neuronas de cada una de las capas ocultas, y otras variables opcionales de acuerdo a la red neuronal que se desee. En este ejemplo, la red neuronal tendrá 1 capa oculta con 3 neuronas.

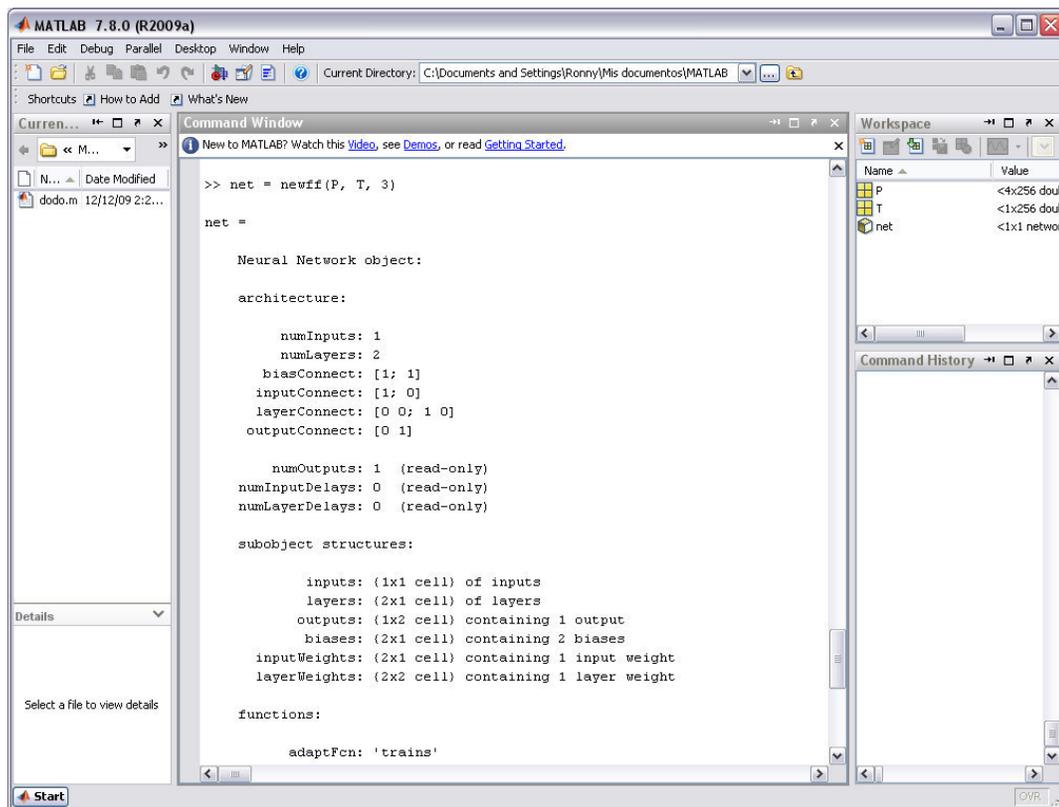


Figura 3.9. Creación de red neuronal.

Fuente: Elaboración propia

4. Se procede a realizar el entrenamiento de la red.

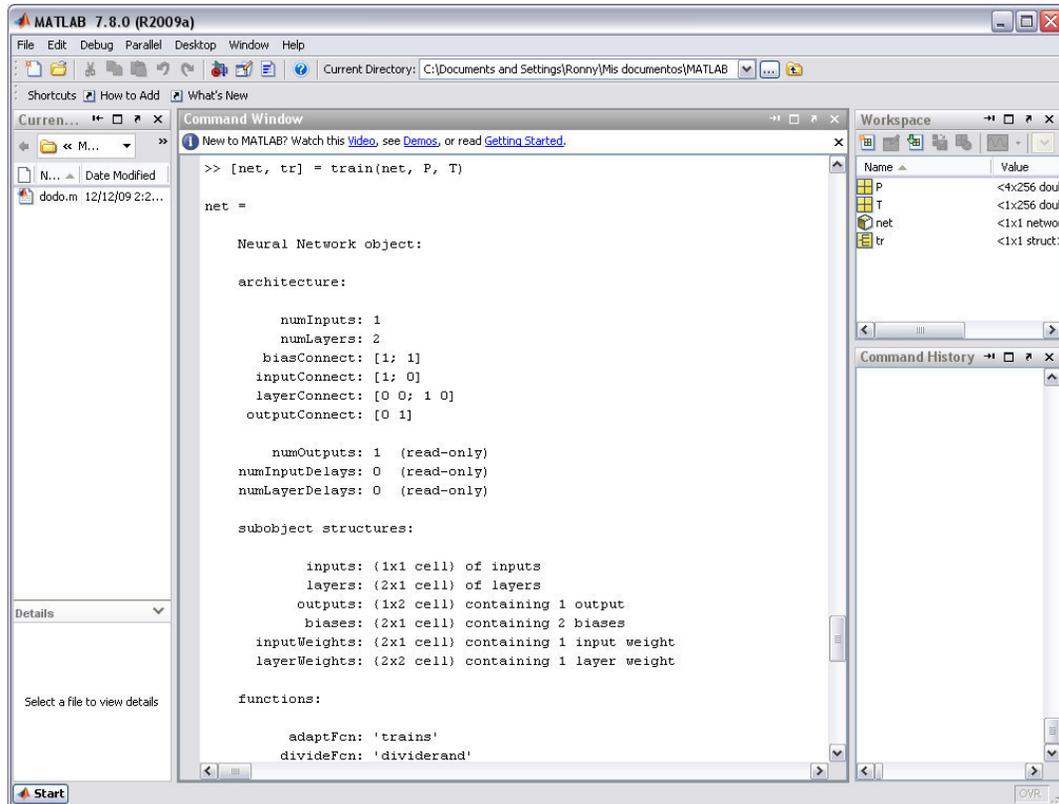


Figura 3.10. Entrenamiento de la red.

Fuente: Elaboración propia

5. Una vez entrenada la red, MATLAB muestra los resultados del entrenamiento.

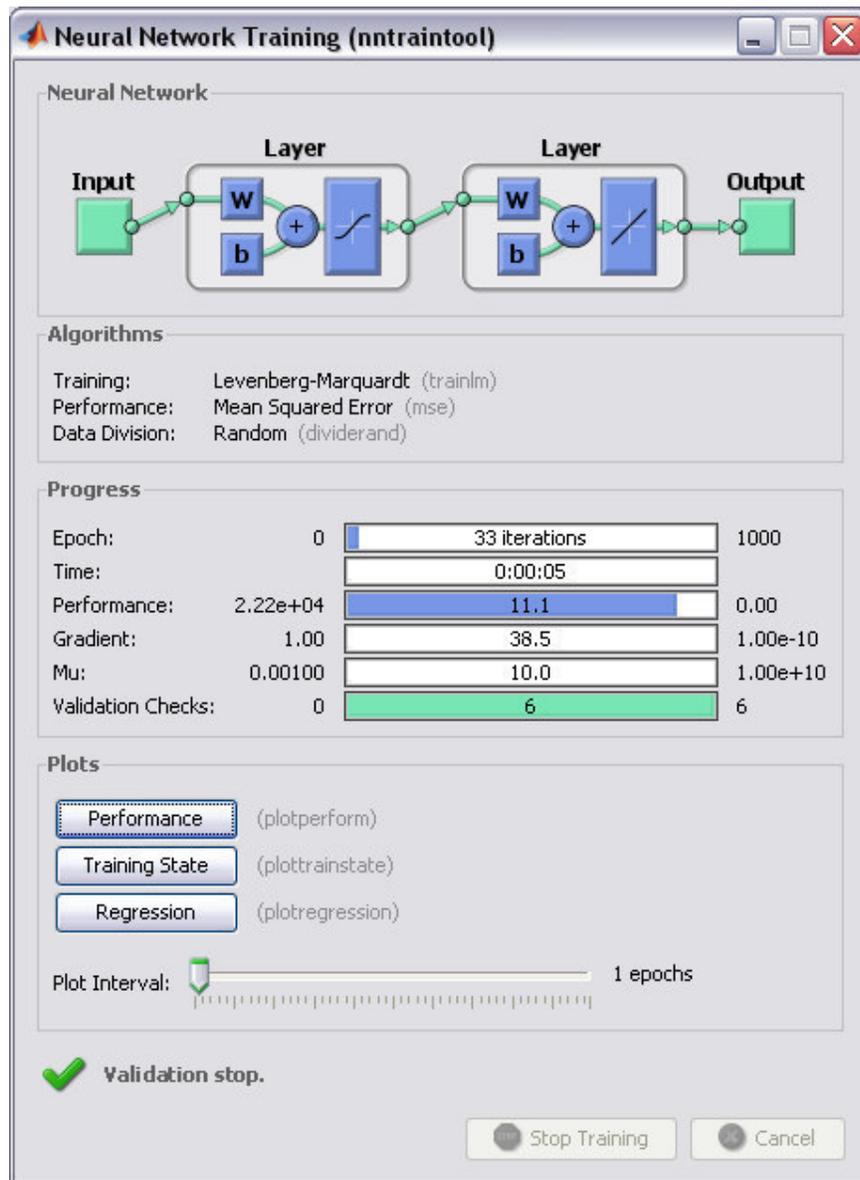
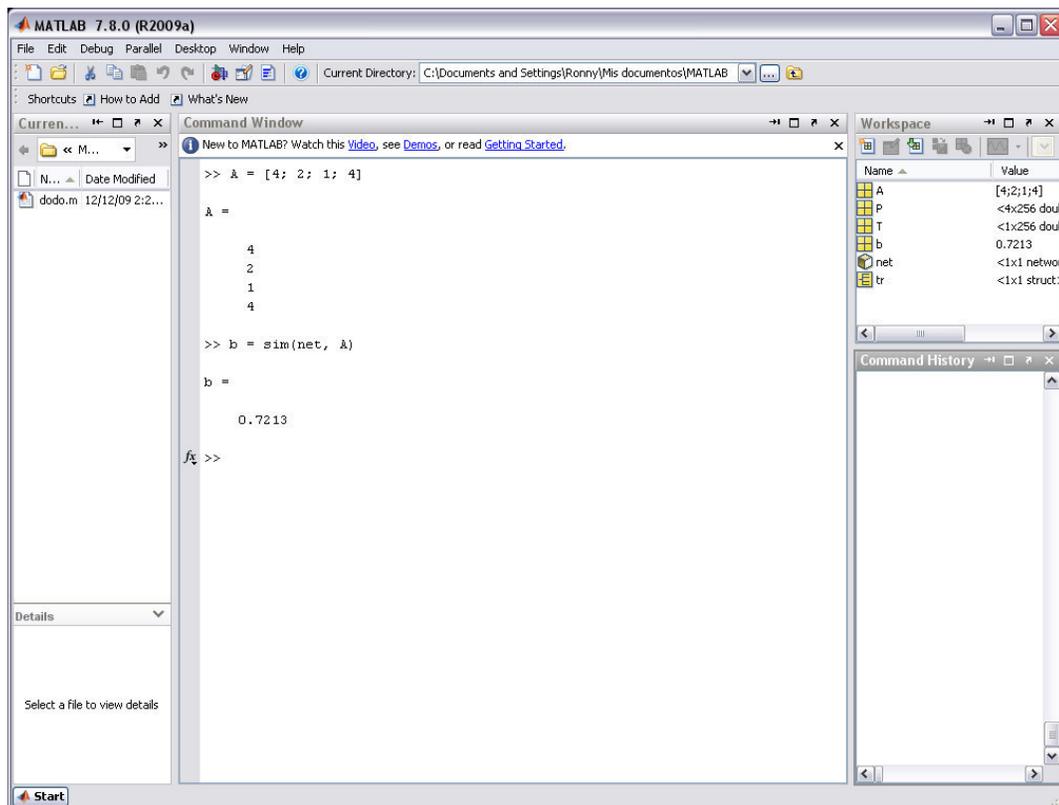


Figura 3.11. Resultados del entrenamiento.

Fuente: Elaboración propia

6. Una vez que la red neuronal ya se encuentra entrenada, ya se pueden simular los resultados para determinada entrada; por ejemplo, si queremos saber cual seria el resultado si las entradas fueran: 4, 2, 1 y 4; primero se tendría que crear un vector con dichos valores, y entonces se ejecutaría la función 'sim' para poder calcular el resultado.



**Figura 3.12. Resultados.**

**Fuente: Elaboración propia**

**OBSERVACIÓN:**

Estos mismos comandos serán usados en la aplicación J2EE, a través de la librería jMatLink.

### 3.6 Interfaces de usuario de la aplicación

Para el desarrollo del sistema de predicción de consumo de electricidad usando redes neuronales artificiales; es necesario la creación de otros proyectos que se encargarán de tratar la data que posteriormente será utilizada para alimentar la red neuronal; entre ellos tenemos:

- Historical usage: Se encargará de obtener el consumo histórico de los clientes reportado por el proveedor de energía (utility), a través de un ESB (Enterprise Service bus). Además dará el formato adecuado a todos los consumos de los usuarios y normalizará la data, generando la data faltante (en caso de que no se cuente con el consumo en determinada fecha u hora).
- Weather service: Se encargará de obtener los datos climáticos pronosticados por un servicio externo contratado, a través de un ESB. Formateará y almacenará la data de acuerdo a los registros de la empresa, para poder ser usados en otros proyectos.
- Otros proyectos.

Sin embargo, para el desarrollo de esta tesina, no se están considerando estos proyectos, ya que escapan del alcance de la tesina.

La data obtenida para la aplicación, se hace directamente de la base de datos y no a través de servicios externos. Así como la data, se encuentra correctamente formateada y no es necesario llevar a cabo otro tipo de validaciones que serían necesarios en el ambiente de producción.

1. Página inicial: página de la empresa.

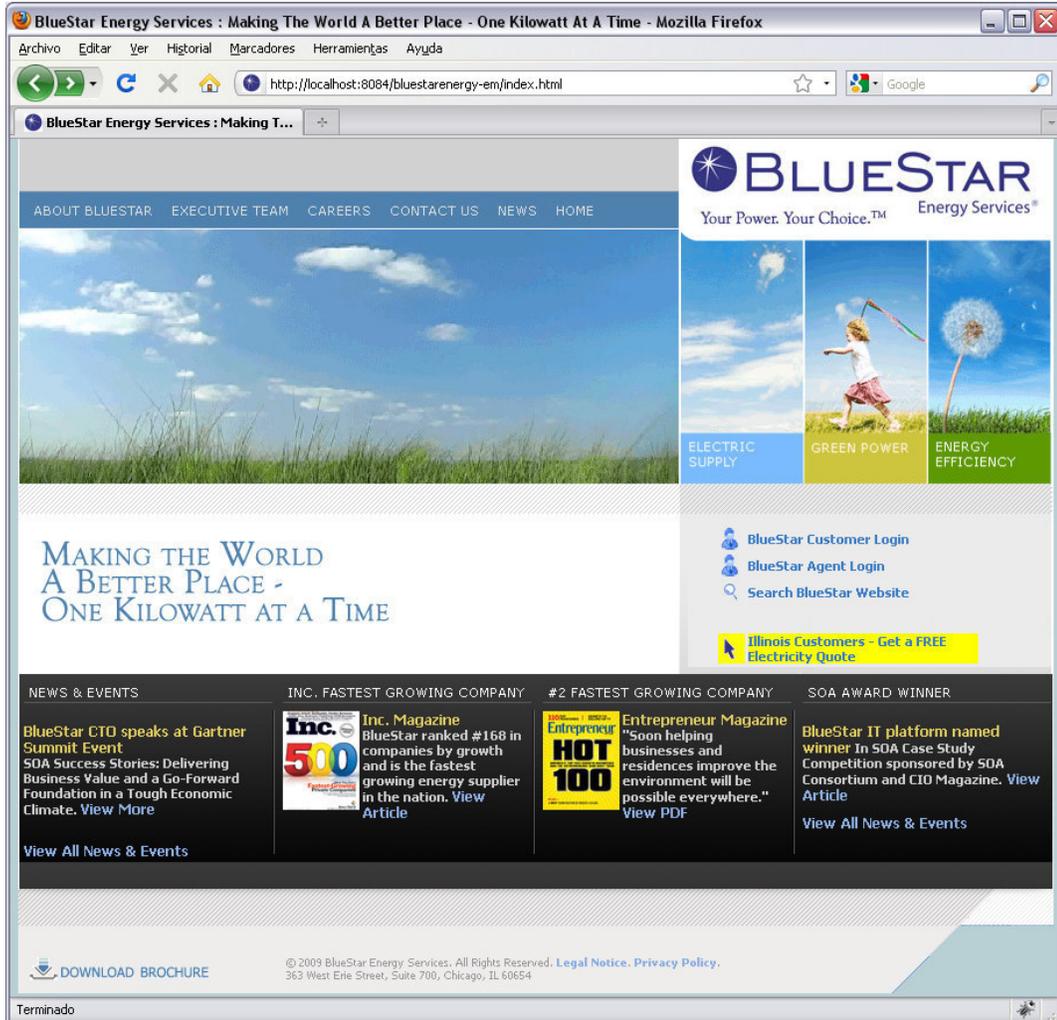
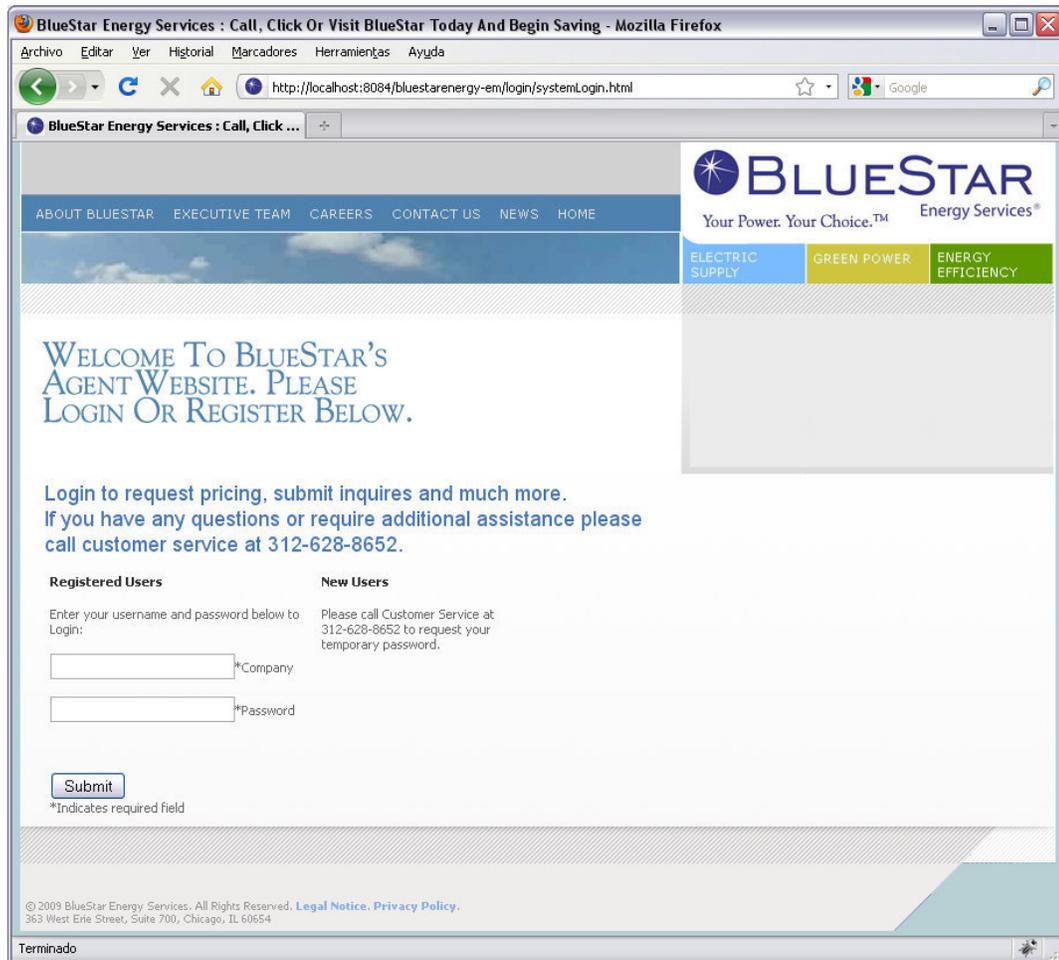


Figura 3.13. Página de inicio.

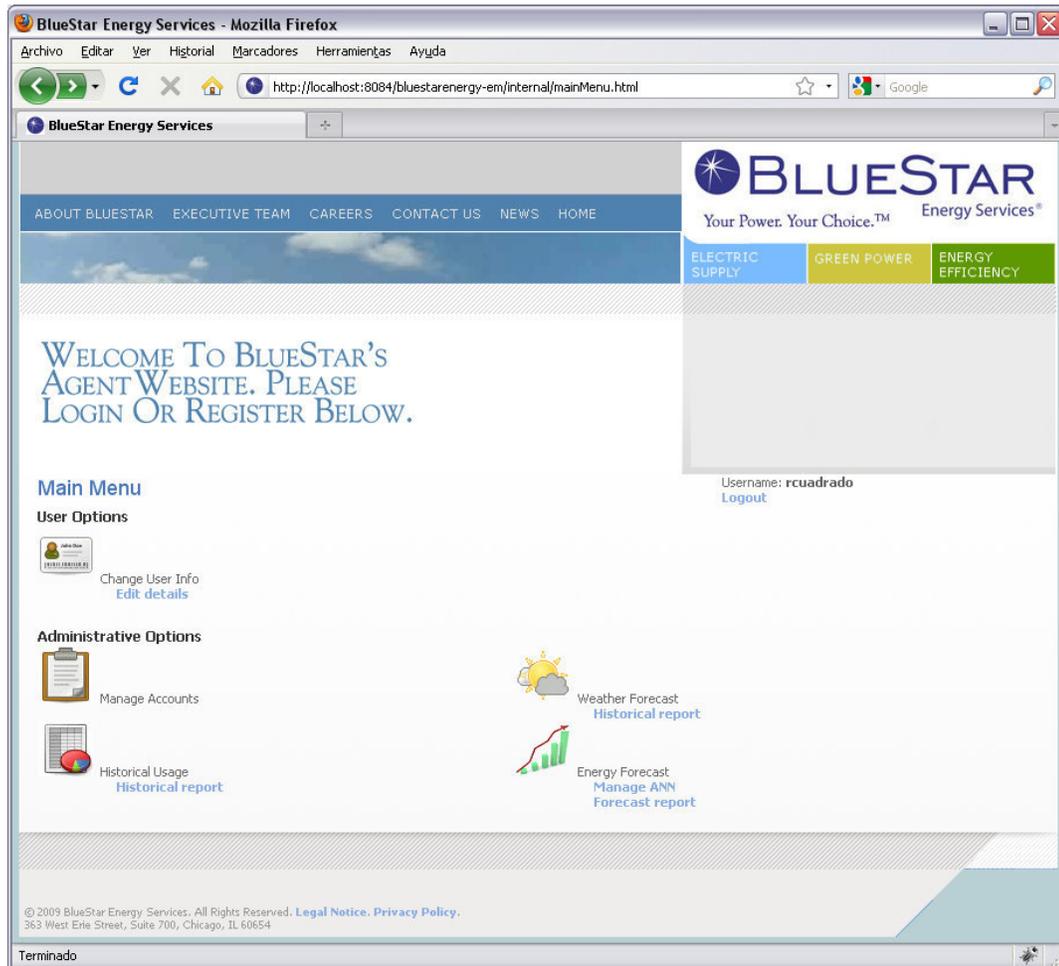
Fuente: Elaboración propia

2. Página de Login: Es necesaria la autenticación y autorización para que solo los usuarios con los permisos adecuados puedan llevar a cabo dichas tareas.



**Figura 3.14. Login.**  
**Fuente: Elaboración propia**

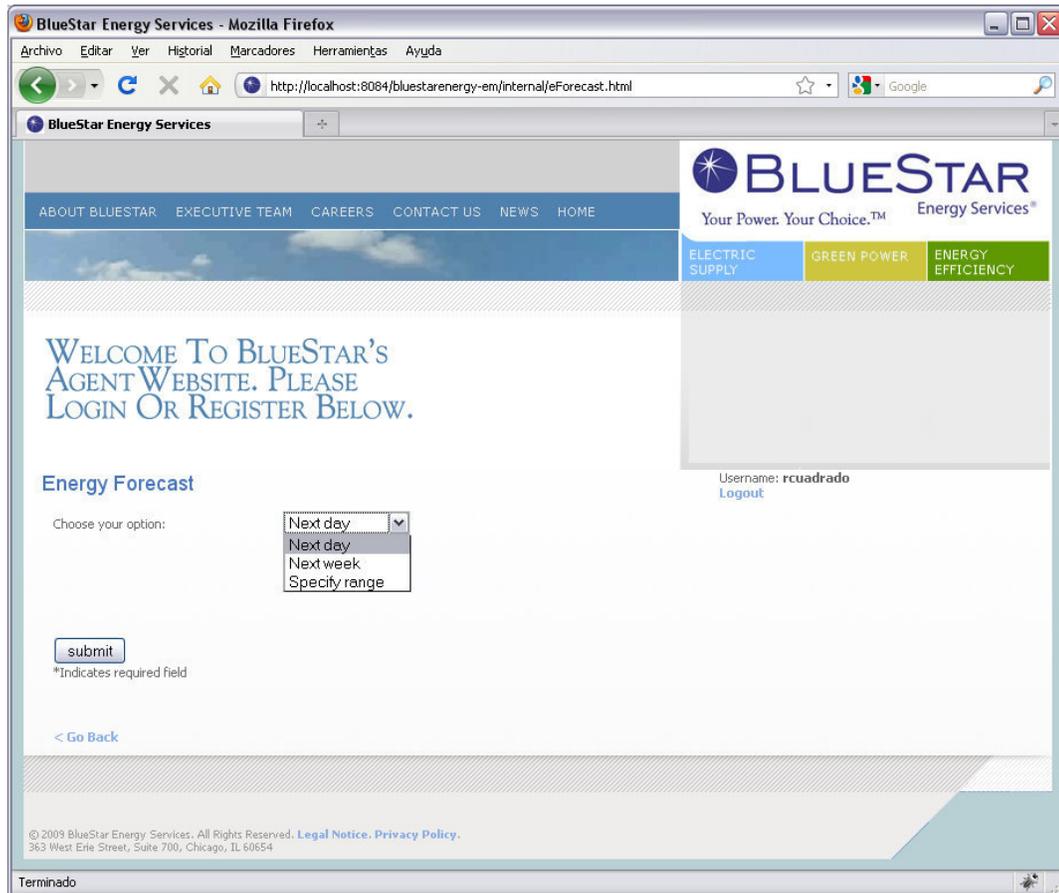
3. Main Menu: Menú principal donde se encuentran las opciones a las cuales puede acceder dicho usuario.



**Figura 3.15. Menú.**

**Fuente: Elaboración propia**

4. Energy Forecast: Página donde se puede seleccionar para que fechas se desea realizar el pronóstico del consumo.



**Figura 3.16. Elección de fechas.**

**Fuente: Elaboración propia**

5. Daily Prediction: Predicción de consumo de electricidad para el día siguiente.

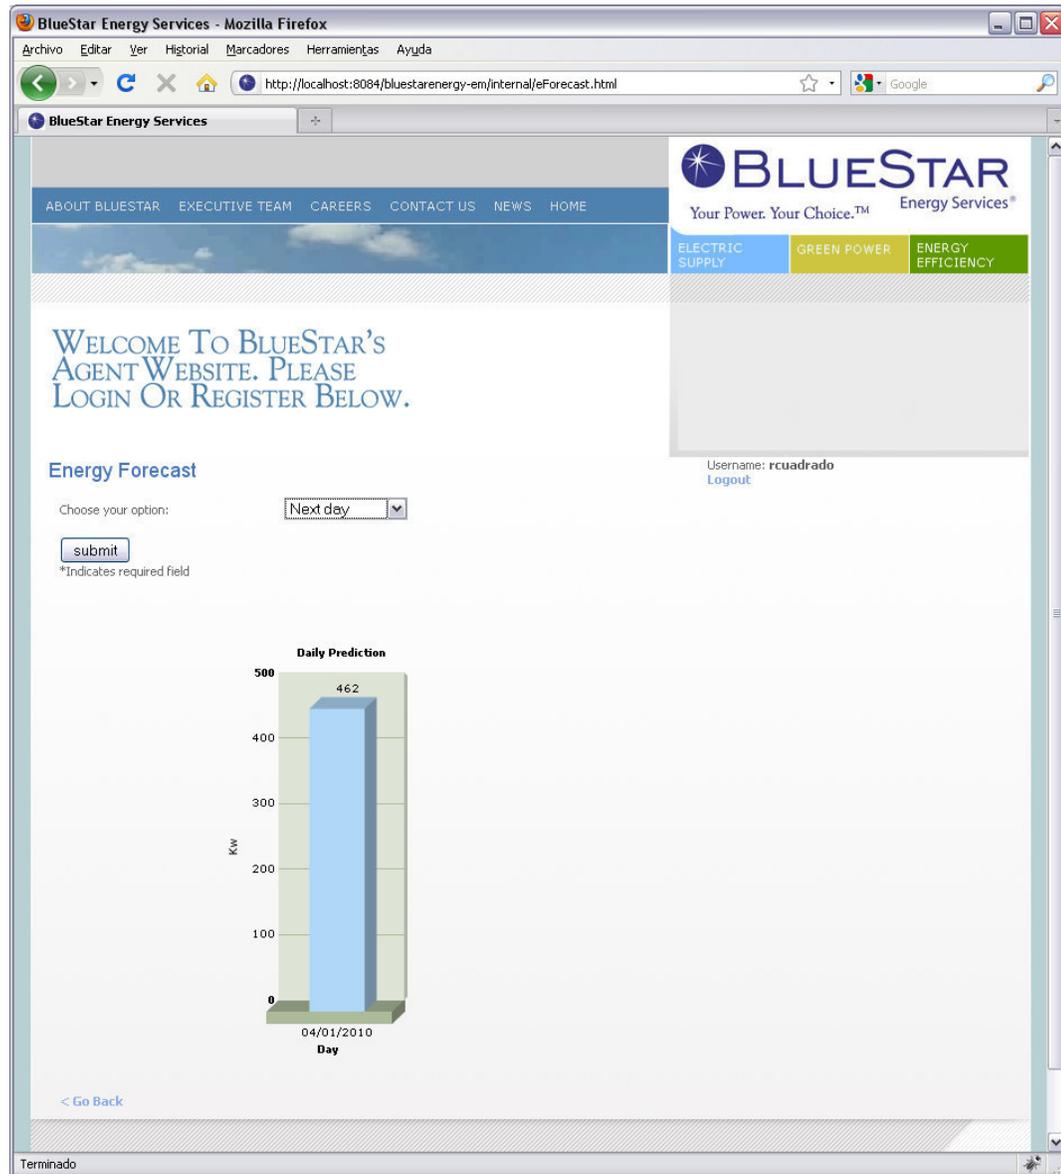


Figura 3.17. Predicción para el día siguiente.

Fuente: Elaboración propia

En la figura 3.17 se puede observar el resultado de la predicción del día siguiente; en este caso el resultado nos dice que el siguiente día se calcula que habrá un consumo de electricidad de 462Kw.

6. Next Week Prediction: Predicción del consumo de electricidad para toda la semana siguiente.

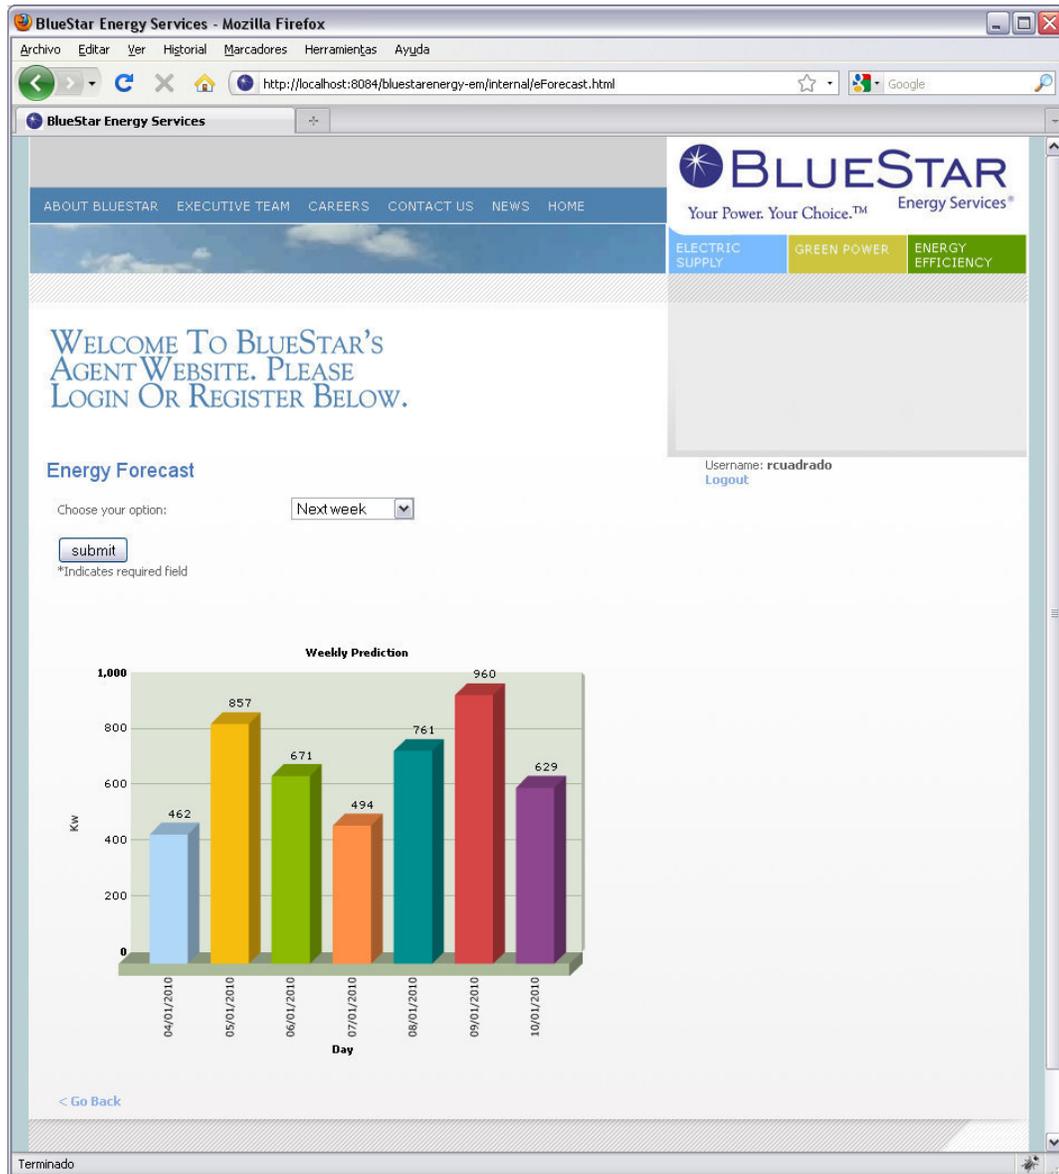


Figura 3.18. Predicción para la semana siguiente.

Fuente: Elaboración propia

En la figura 3.18 se puede observar el resultado de la predicción de la siguiente semana, comenzando desde el lunes. En este caso se muestra el consumo calculado para cada uno de los días.

7. Specify Range Prediction: Predicción de consumo de electricidad para un rango de fechas definida por el usuario. El rango de fechas máximo a pronosticar es de 2 semanas adelante.

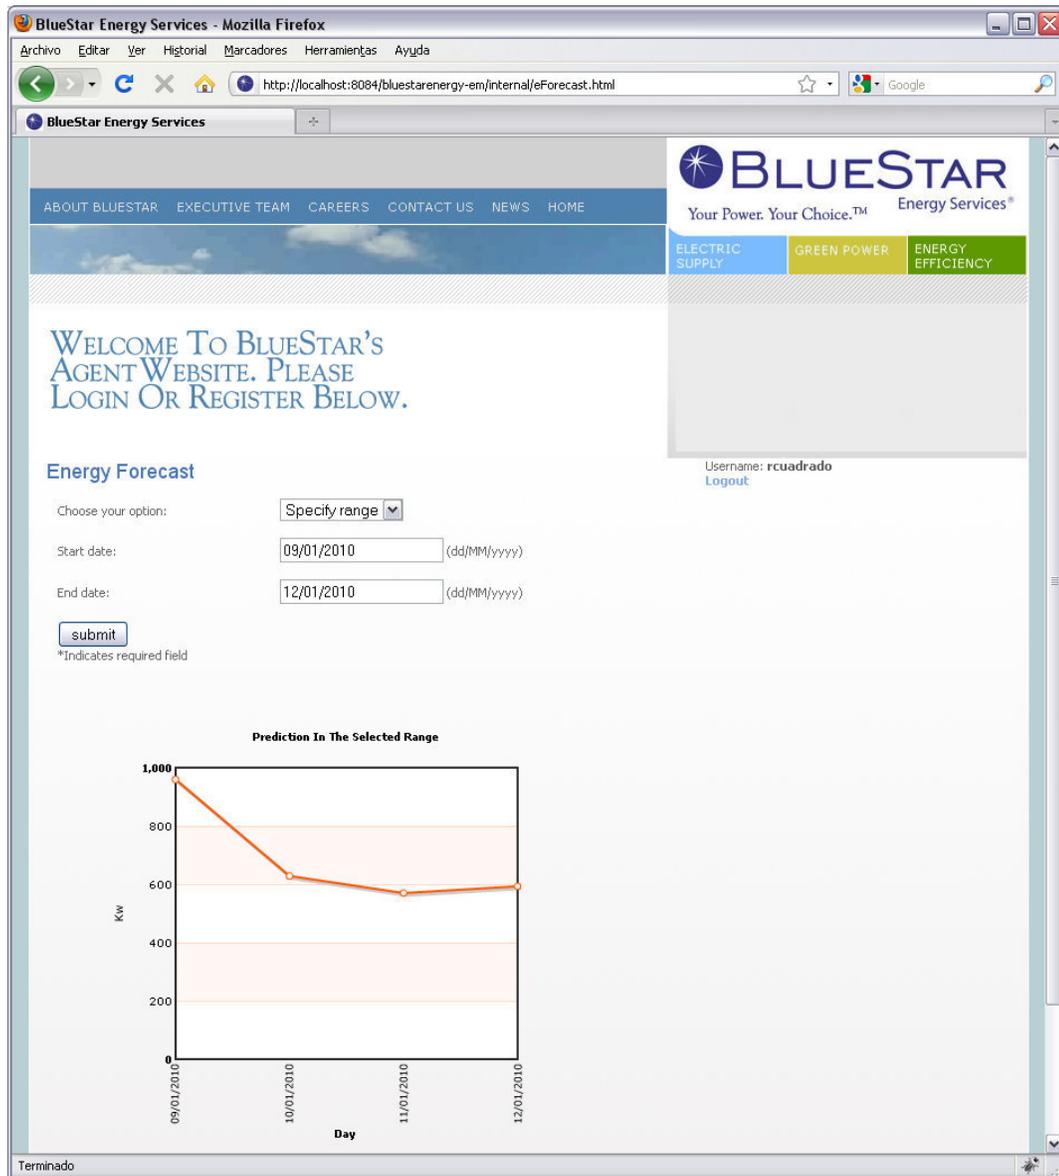


Figura 3.19. Predicción para un rango determinado.

Fuente: Elaboración propia

En la figura 3.19 se puede observar el resultado de la predicción para un rango de fechas. La figura muestra el consumo de cada día para ese rango de fechas.

## **CAPÍTULO IV: CONCLUSIONES Y RECOMENDACIONES**

## Conclusiones

1. Se demuestra que a través de RNA, se logra un mejor pronóstico de la demanda eléctrica, pero para ello, es necesario una gran cantidad de información, a fin de obtener resultados con una mayor precisión.
2. Queda demostrada la incidencia que tienen las variables que influyen en la predicción de la demanda eléctrica (la temperatura, la humedad, etc.), para la obtención de mejores resultados.
3. Se desarrolló una aplicación para la predicción de la demanda compatible con el resto de sistemas de la empresa, gracias al uso de la librería JMatLink, para integrar la aplicación con MATLAB.
4. Se cumplió con el objetivo de hacer uso del software MATLAB para la creación, entrenamiento y simulación de los resultados, en el desarrollo de la red neuronal.
5. Se comprueba que al emplear redes neuronales para el pronóstico de la demanda de electricidad, se logró disminuir las pérdidas económicas producidas por un pronóstico inexacto.
6. Se destaca que el modelo de red neuronal usado (perceptrón multicapa) con 1 capa oculta, es adecuado para obtener un buen nivel de precisión; logrando así optimizar el pronóstico de la demanda en la empresa BlueStar.

## Recomendaciones

1. Se debe de evaluar la metodología más adecuada, de acuerdo a la empresa donde de vaya a implementar.
2. Se propone consultar con especialistas en el negocio de la electricidad, para mejorar la red neuronal.
3. Se propone hacer una comparación de resultados, usando otro simulador de redes neuronales.
4. Sería de interés probar con otras reglas de aprendizaje diferentes a la de Backpropagation que fue la que se presentó aquí, ya que esto se refleja directamente en el ajuste de los pesos y por consiguiente en el ajuste final de la red.
5. Se recomienda revisar la documentación del programa MATLAB, para poder personalizar de una mejor manera el uso de las funciones para el entrenamiento y simulación de la red neuronal.
6. La tecnología de la Inteligencia Artificial y las redes neuronales posee gran potencial por lo que se recomienda ahondar en su estudio para posterior aplicación en otras áreas.

## Bibliografía

- [HAY 1998] HAYKIN, SIMON, “**Neural Networks: A Comprehensive Foundation**”, Editorial PRENTICE-HALL, INC. 1998.
- [HIL 1995] HILERA, JOSÉ y MARTINEZ, VICTOR, “**Redes Neuronales Artificiales. Fundamentos, Modelos Y Aplicaciones**”, Editorial RA-MA, España, 1995.
- [QUI 2007] QUINTIN, MARTIN, “**Aplicación de las redes neuronales artificiales**”, Editorial LA MURALLA, 2007
- [TAY 1996] TAYLOR, JOHN, “**Neural Networks and Their Applications**”, Editorial WILEY, 1996
- [MAR 2001] MARTÍN DEL BRÍO, BONIFACIO Y SANZ, ALFREDO, “**Redes Neuronales y Sistemas Borrosos**”, Editorial, RAMA, España, 2001
- [CAM 2006] CAMPEROS, SÁNCHEZ, “**Redes neuronales: conceptos fundamentales y aplicaciones a control automático**”, Editorial Prentice Hall, España, 2006
- [WEB1] [http://vidaartificial.com/index.php?title=Una Introduccion a las Redes Neuronales %28Generation5.org%29](http://vidaartificial.com/index.php?title=Una_Introduccion_a_las_Red_Neuronales_%28Generation5.org%29)
- [WEB2] <http://ciberconta.unizar.es/LECCION/REDES/INICIO.HTML>
- [WEB3] [http://www.iansa.com.pe/Paper\\_pronos\\_iansa.PDF](http://www.iansa.com.pe/Paper_pronos_iansa.PDF)

- [WEB4] <http://www.aedie.org/11chlie-papers/179-Yanguas.pdf>
- [WEB5] <http://www.robcas64.com/Automatizacion/PronosticoCar gaRNN .pdf>
- [WEB6] <http://web.ing.puc.cl/~power/alumno98/eeuu/desregulacion.htm>
- [WEB7] <http://www.bluestarenergy.com/electricsupply-dereg.html>
- [WEB8] [http://exa.unne.edu.ar/depar/areas/informatica/Sistemas Operativos/Mineria\\_Datos\\_Vallejos.pdf](http://exa.unne.edu.ar/depar/areas/informatica/Sistemas Operativos/Mineria_Datos_Vallejos.pdf)
- [WEB9] [http://trevinca.ei.uvigo.es/~anton/cursosofuzzy/predic\\_electrica.pdf](http://trevinca.ei.uvigo.es/~anton/cursosofuzzy/predic_electrica.pdf)
- [WEB10] <http://books.google.com.pe/books?id=LjWfRnueXrYC>
- [WEB11] <http://www.redes-neuronales.netfirms.com/tutorial-redes-neuronales>
- [WEB12] <http://bieec.epn.edu.ec:8180/dspace/bitstream/123456789/1212/8/T%2011076%20CAPITULO%202.pdf.pdf>
- [WEB13] <http://itzamna.bnct.ipn.mx:8080/dspace/bitstream/123456789/2714/1/PRONOSTICODEDEMANDADEENERGIA.pdf>
- [WEB14] [http://es.wikipedia.org/wiki/Redes\\_neuronales](http://es.wikipedia.org/wiki/Redes_neuronales)
- [WEB15] <http://parisinet.com/cs/articulos/archivos/lógica%20borrosa%20OIPS A.doc>

[WEB16]

[http://athenea.ort.edu.uy/publicaciones/intart/Proceed/BOLETI  
N.pdf](http://athenea.ort.edu.uy/publicaciones/intart/Proceed/BOLETI<br/>N.pdf)