



COLEGIO DE ESTUDIOS SUPERIORES DE ADMINISTRACIÓN

CESA

Administración de Empresas

Pasantía de investigación:

“Pronósticos:

Métodos Cualitativos y Cuantitativos vs. Métodos de Inteligencia Artificial”

Presentado por:

Laura Jaramillo Ramírez

Marzo/2012

TABLA DE CONTENIDO

INTRODUCCIÓN.....	3
1. MÉTODOS CUALITATIVOS.....	5
1.1. Investigación de Mercados	5
1.2. Consenso de Panel y Método Delphi.....	5
1.3. Analogía por Ciclo de Vida.....	6
1.4. Valoración o juicio informado.....	6
2. MÉTODOS CUANTITATIVOS.....	7
2.1. Método de Relación Causal o Regresión.....	7
2.2. Series de Tiempo	7
3. MÉTODOS DE INTELIGENCIA ARTIFICIAL.....	10
3.1. Redes Neuronales Artificiales (RNA).....	10
3.2. Lógica Difusa.....	14
3.3. Sistemas Expertos.....	17
3.4. Algoritmos Genéticos.....	18
4. APLICACIONES DE LOS MÉTODOS DE INTELIGENCIA ARTIFICIAL	
20	
4.1. Redes Neuronales para pronosticar el PIB de Colombia:	20
4.2. Redes Neuronales para pronosticar el IGBC:.....	20
4.3. Redes Neuronales para pronosticar la demanda:	21
4.4. Lógica Difusa para pronosticar los niveles medios diarios del rio Magdalena:..	22
4.5. Lógica Difusa para pronosticar la demanda:	23
4.6. Sistemas Expertos para pronosticar la demanda:	24
4.7. Algoritmos Genéticos para pronosticar el rendimiento futuro de acciones:	25
CONCLUSIÓN	27
BIBLIOGRAFÍA.....	29

TABLA DE FIGURAS

Figura 1: Esquema de una Red Neuronal Monocapa.....	12
Figura 2: Esquema de una Red Neuronal Multicapa.....	12
Figura 3: Lógica Borrosa vs. Lógica Clásica.....	16

INTRODUCCIÓN

Para que las empresas tengan éxito y perduren en el tiempo deben trazarse unas metas claras a futuro y crear un plan de acción para conseguirlas. Sin embargo, esa no es una tarea fácil, en el mundo actual que se caracteriza por tener un ambiente inestable y sujeto a cambios imprevisibles, los empresarios deben contar con información suficiente y con el menor grado de incertidumbre posible a la hora de tomar las decisiones que van a definir como se van a distribuir sus recursos financieros humanos y tecnológicos.

Debido a lo anterior, cada vez más empresas han redefinido y formalizado los procesos de elaboración de pronósticos para llevar a cabo una mejor planeación de sus ventas y su operación. No es nuevo para nadie que el reto de todas las empresas es contar con la cantidad de producto o servicio necesaria según los requerimientos del mercado. (Correa, 2009)

“Para entregar un mejor nivel de servicio de manera rentable las empresas requieren desarrollar una cultura de predicción y planeación. Cuando se elabora un mal pronóstico, la planeación se viene abajo y todas las áreas de la empresa se vuelven ineficientes. Esto se puede observar directamente en el bajo desempeño financiero de la empresa. Ventas negadas, excesos de inventarios de productos que no requieren los clientes, reducción de margen al vender con descuentos para lograr los objetivos, costos más altos en las compras, producción y/o distribución para reaccionar a emergencias, etc., ... estos son los síntomas.” (Correa, 2009)

”Pronosticar es el arte y ciencia de predecir acontecimientos futuros.” (Cohen, (s.f.)) Sin embargo, es importante aclarar que “el pronóstico no es una predicción de lo que irremediablemente pasará en el futuro. Un pronóstico es información con cierto grado de probabilidad de lo que pudiera pasar.” (Correa, 2009)

Podemos definir tres horizontes temporales sobre los cuales se pronostica que son: largo, mediano y corto plazo. Los pronósticos de largo plazo son necesarios para establecer el curso general de las empresas, se usan generalmente para definir localización de nuevas instalaciones, adquisición de maquinaria y planeación de nuevos

productos, entre otros. Los pronósticos de mediano plazo se usan para planificar las ventas, la producción y el presupuesto, y los pronósticos de corto plazo se usan para diseñar estrategias inmediatas, por ejemplo la programación de trabajos y asignación de tareas. (Cohen, (s.f.))

Adicionalmente, los pronósticos se pueden clasificar en dos grandes grupos que son: cualitativos y cuantitativos. “Cuando la situación no es clara y hay pocos datos, como por ejemplo al estudiar el lanzamiento de un producto innovador o una nueva tecnología, se recurre a métodos cualitativos, donde prevalece la intuición. Por el contrario, cuando la situación es más estable y existen datos históricos, se suelen utilizar los métodos cuantitativos.” (Cohen, (s.f.))

En los últimos años la tecnología ha evolucionado en una forma nunca antes vista y, asimismo, los pronósticos también han evolucionado. Es por lo anterior que ha surgido un tercer grupo de clasificación de los pronósticos basado en la inteligencia artificial, en el cual se combina la computación con los métodos cualitativos y los métodos cuantitativos.

A continuación se explican los métodos más importantes que hacen parte de estos tres grupos y a través de ejemplos de la vida real se demuestra porque los Métodos de Inteligencia Artificial en general permiten obtener mejores resultados que los Métodos Clásicos (Cualitativos y Cuantitativos).

1. MÉTODOS CUALITATIVOS

Los métodos cualitativos se basan en la experiencia y el juicio de las personas. Los pronósticos que se obtienen de estos métodos tienden a ser subjetivos porque con frecuencia están sesgados a las posiciones optimistas o pesimistas de las personas involucradas. Una de las ventajas de estos métodos radica en que permite obtener resultados con bastante rapidez. (Chapman, 2006)

1.1. Investigación de Mercados

“Son, casi siempre, cuestionarios estructurados que se envían a los clientes potenciales del mercado. En ellos se solicita su opinión acerca de productos o productos potenciales, y muchas veces intentan también averiguar la probabilidad de que los consumidores demanden ciertos productos o servicios. Si se estructuran bien, se aplican a una buena muestra representativa de la población definida, y se les analiza correctamente, pueden ser muy efectivas, especialmente en el corto plazo. Un importante defecto de las encuestas de mercado es que son bastante caras, y su aplicación es lenta si se realizan correctamente.” (Chapman, 2006)

1.2. Consenso de Panel y Método Delphi

“Utilizan paneles de expertos específicos en el mercado o área para la cual se desarrolla la encuesta. Los expertos intentan transferir al análisis su conocimiento individual respecto de los factores que afectan la demanda, interactuando entre sí para tratar de llegar a un consenso en cuanto al pronóstico de la demanda para los productos o familias de productos en cuestión. La principal diferencia entre los dos métodos radica en el proceso. Mientras que el pronóstico de panel tiende a reunir a los expertos en una junta formal para que se lleve a cabo la discusión, el método Delphi permite que cada experto realice una serie de pronósticos individuales: uno a uno desarrollan su pronóstico particulares con sus propios motivos definidos; después, el conjunto de pronósticos generados por la colectividad es distribuido entre todos los expertos, lo cual permite que cada uno modifique sus proyecciones con base en la información de los demás. La idea es obtener, mediante la repetición de esta serie de pasos, un consenso

acerca del pronóstico.” (Chapman, 2006) Estos métodos son bastante precisos cuando se realizan correctamente, sin embargo, también tienden a ser bastante caros debido a que los expertos cobran tarifas muy altas por su tiempo y sus observaciones. (Chapman, 2006)

1.3. Analogía por Ciclo de Vida

Este método se utiliza para productos o servicios nuevos y se basa en el hecho de que casi todos los productos y servicios tienen un ciclo de vida bien definido. En primer lugar el producto o servicio es introducido al mercado, en la etapa temprana experimenta un crecimiento sostenido hasta llegar a la madurez donde el crecimiento es muy bajo o nulo, finalmente la demanda del producto declina hasta el punto en que debe salir del mercado. El método consiste en buscar y observar un producto o servicio que sea similar al que está por salir al mercado, el ciclo de vida y la demanda del producto o servicio nuevo será a grandes rasgos igual que para el producto o servicio que se observó. (Chapman, 2006)

1.4. Valoración o juicio informado

“Se agrupan y revisan estimaciones de ventas esperadas por los vendedores, y luego se obtiene un pronóstico global. Se debe tener cuidado con los intereses que pueden tener, ya que normalmente van a subestimar ó sobreestimar en función de la metodología de incentivos por ventas que se encuentre en vigencia. Si cobran un porcentaje sobre las ventas, sobreestimarán la demanda con tal de que no les falte producto para vender. Si cobran en función al grado en el cual superan un objetivo, subestimarán la demanda, para negociar un objetivo menor y así superarlo más ampliamente o con menor esfuerzo.” (Cohen, (s.f.))

2. MÉTODOS CUANTITATIVOS

En general existen solo dos tipos de modelos de pronóstico cuantitativos: Los de relación causal o regresión y los de series de tiempo. Los pronósticos de relación causal explican el comportamiento de una variable dependiente, en función de otra u otras independientes; en cambio, los pronósticos de series de tiempo pronostican una variable en función de su propio pasado. (Cadena, 2010)

2.1. Método de Relación Causal o Regresión

“La regresión es una técnica estadística utilizada para estimar y analizar la relación funcional existente entre dos o más variables. Como su nombre lo indica, esta técnica requiere de información del pasado de las variables; la idea es identificar la naturaleza que subyace en los datos (patrón de comportamiento) para reproducir dicho comportamiento hacia el futuro.” (Cadena, 2010)

“Existen dos tipos de regresión desde el punto de vista del número de variables: la regresión simple que tiene en cuenta únicamente dos variables y la regresión múltiple que se extiende a más variables. (...) En consecuencia, lo que se busca con el análisis de regresión es analizar como una o más variables explicativas, denominadas Xs, afectan a la variable de interés o a explicar, denominada Y.” (Cadena, 2010)

2.2. Series de Tiempo

“Todos los pronósticos de series de tiempo parten, básicamente, de un supuesto común: que la demanda pasada sigue cierto patrón, y que si este patrón puede ser analizado podrá utilizarse para desarrollar proyecciones para la demanda futura, suponiendo que el patrón continúa aproximadamente de la misma forma. Esto implica el supuesto de que la única variable independiente en el pronóstico de series de tiempo es, precisamente, el tiempo.” (Chapman, 2006)

“Casi todos los modelos de pronóstico de series de tiempo intentan capturar de manera matemática los patrones subyacentes de la demanda pasada”. (Chapman, 2006) Estos

patrones son: La tendencia, que puede ser positiva o negativa dependiendo del comportamiento de los datos a lo largo del tiempo; la estacionalidad, que se refiere a las fluctuaciones que se presentan en periodos menores a un año y que se suele repetir año tras año; los ciclos; que son patrones que ocurren en los datos cada varios años, y las variaciones aleatorias, que son las variaciones en los datos que se presentan por el azar y las situaciones inusuales. (Cohen, (s.f.))

A través de los años se han desarrollado muchísimos métodos de series de tiempo para pronosticar teniendo en cuenta la existencia de los patrones anteriormente descritos. Algunos de los métodos más conocidos son los siguientes:

- Promedio Móvil Simple: Es un método que se utiliza para suavizar los patrones de comportamiento de una serie de datos. Consiste en tomar el promedio matemático de los últimos periodos recientes de los datos. Mientras más periodos se utilicen para calcular el pronóstico, el resultado será más suave. (Chapman, 2006)
- Promedio Móvil Ponderado: Es básicamente lo mismo que el promedio móvil simple, la única diferencia es que se le asigna un peso diferente a cada dato que se utiliza en el calculo, según el juicio y la experiencia de quienes lo estén realizando. (Chapman, 2006)
- Suavización Exponencial: Es un promedio móvil ponderado en el cual se le asigna un mayor peso a los periodos más recientes de la serie. (Chapman, 2006). Los dos modelos anteriores solo aplican para series estacionarias, es decir, cuando estas no tienen tendencia ni variabilidad.
- Método de Holt-Winter: Este método de suavizamiento incluye tres ecuaciones que además de suavizar la serie como los anteriores, recoge la posible tendencia y estacionalidad de la serie para efectos de replicar dichos patrones en el pronóstico.
- ARIMA (Autoregressive Integrated Moving Average): Este es un método estadístico que a diferencia de los anteriores, que se suponen determinísticos, es decir, con un comportamiento “f cilmente predecible”, se utiliza cuando las series de tiempo tienen un comportamiento muy volátil y se requiere de métodos

mas sofisticados que los deterministas. Este método de reciente creación se basa en el calculo de innumerables regresiones y del análisis del correlograma, un instrumento grafico que permite identificar patrones pasados de comportamiento y de esta manera replicarlos hacia el futuro. Su mayor aplicación se ha concentrado en el pronóstico de series financieras y económicas.. (Cadena, 2010)

3. MÉTODOS DE INTELIGENCIA ARTIFICIAL

Los métodos de Inteligencia Artificial cuentan con formas de afrontar problemas que antes parecían imposibles y también con formas más eficientes de resolver problemas que hoy ya tienen solución. Lo anterior se debe al descubrimiento de nuevas técnicas, y/o combinación de técnicas existentes que permiten aprovechar las ventajas y superar las debilidades de cada una. (DMoZ, (s.f.))

La inteligencia artificial (IA) es la parte de las ciencias computacionales encargada de diseñar sistemas que presentan características asociadas con el comportamiento humano inteligente. (DMoZ, (s.f.)) Estos métodos han demostrado ser mucho más efectivos que los métodos clásicos (cualitativos y cuantitativos) ya que tienen la capacidad de modelar sistemas complejos no lineales donde no se tiene información completa. Algunos de los métodos de inteligencia artificial que existen actualmente son los siguientes:

3.1. Redes Neuronales Artificiales (RNA)

“El cerebro es un procesador de información con características notables: es capaz de procesar a gran velocidad grandes cantidades de información procedentes de los sentidos, combinarla o compararla con la información almacenada y dar respuestas adecuadas, incluso en situaciones nuevas. Logra discernir un susurro en una sala ruidosa, distinguir una cara en una calle mal iluminada o leer entre líneas en una declaración política; pero lo más impresionante es su capacidad de aprender a representar la información necesaria para desarrollar habilidades sin instrucciones explícitas para ello.” (Molina, Toro, & Garcés, 2005)

A pesar de que todavía se desconoce bastante acerca de la forma en que el cerebro aprende a procesar la información, se han desarrollado modelos que tratan de imitar esas habilidades, denominados redes neuronales artificiales. Su elaboración supone en primer lugar la deducción de las características esenciales de las neuronas y sus conexiones, y en segundo lugar, la implementación del modelo en un computador de tal forma que se pueda simular. (Molina, Toro, & Garcés, 2005)

De acuerdo con Cruz, Restrepo & Medina, 2009, los modelos de Redes Neuronales Artificiales funcionan de la siguiente forma:

- El modelo recibe diferentes entradas de otras neuronas o ambientes.
- Las entradas alimentan la red a través de conexiones y pesos. Estas conexiones pueden ser excitadoras o inhibitoras (conexiones positivas o negativas).
- Un sumador se encarga de sumar todas las entradas multiplicadas por los respectivos pesos.
- Una función de activación no lineal limita la amplitud de las salidas de la neurona.
- Las salidas van a otras neuronas o ambientes.

Los elementos básicos de la Red que se mencionan anteriormente se conectan entre sí para dar lugar a las estructuras neuronales que se pueden clasificar de diferentes formas según los patrones fundamentales de la red que son el número de capas, el tipo de conexiones y el grado de conectividad.

Según el número de capas:

- Redes Neuronales Monocapa: Son las redes neuronales más sencillas. Únicamente cuentan con una capa de neuronas, que intercambian señales con el exterior y que constituyen al mismo tiempo la entrada y salida del sistema. “Se utiliza generalmente en tareas relacionadas con la autoasociación; por ejemplo para regenerar informaciones de entrada que se presentan a la red incompletas o distorsionadas.” (Villanueva, (s.f.))




Figura 1: Esquema de una Red Neuronal Monocapa. (Molina, Toro, & Garcés, Ponóstico de Acciones en Bolsa de Valores Usando Técnicas Inteligentes, 2005)

- Redes Neuronales Multicapa: “s una generalización de la anterior existiendo un conjunto de capas intermedias entre la entrada y la salida (capas ocultas). ste tipo de red puede estar total o parcialmente conectada.” (Soria & Blanco, (s.f.))

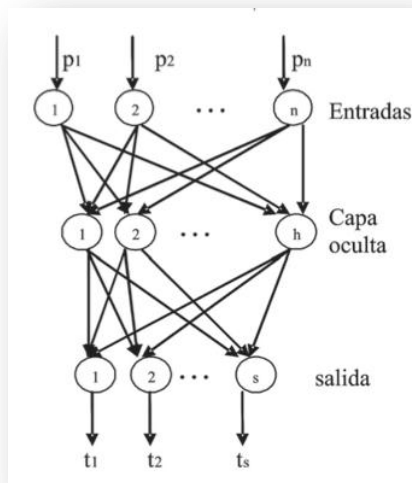


Figura 2: Esquema de una Red Neuronal Multicapa. (Molina, Toro, & Garcés, Ponóstico de Acciones en Bolsa de Valores Usando Técnicas Inteligentes, 2005)

Según el tipo de conexiones:

- Redes Neuronales no Recurrentes: Son estructuras que no tienen memoria. Las señales se propagan únicamente en un sentido, por lo que no existe la

posibilidad de realimentaciones. También se conocen como redes de conexiones hacia delante o feedforward. (Soria & Blanco, (s.f.))

- Redes Neuronales Recurrentes: Se caracteriza por la existencia de lazos de realimentación. Estos lazos pueden ser entre neuronas de diferentes capas, neuronas de la misma capa o entre una misma neurona. También se conocen como redes de conexiones tanto hacia delante como hacia atrás o redes feedforward/feedback. Este tipo de redes se utiliza para estudiar la dinámica de sistemas no lineales y son especialmente útiles en aplicaciones de reconocimiento o clasificación de patrones. (Soria & Blanco, (s.f.))

Según el grado de conectividad:

- Redes Neuronales Totalmente Conectadas: Todas las neuronas de una capa se encuentran conectadas con las de la capa siguiente (redes no recurrentes) o con las de la capa anterior (redes recurrentes). (Soria & Blanco, (s.f.))
- Redes Neuronales Parcialmente Conectadas. No se presenta una conexión total entre neuronas de diferentes capas. (Soria & Blanco, (s.f.))

Las RNA también se pueden clasificar según su mecanismo de aprendizaje, cada conexión neuronal tiene un peso numérico asociado. Los pesos son el medio para el almacenamiento a largo plazo en una estructura neuronal, y el aprendizaje se hace al actualizar dichos pesos. (Vera & Bustamante, 2007)

- Aprendizaje supervisado: “Ocurre cuando se le proporciona a la red tanto la entrada como la salida correcta, y la red ajusta sus pesos tratando de minimizar el error de su salida calculada.” (Vera & Bustamante, 2007)
- Aprendizaje no supervisado: “Se presenta cuando a la red se le proporcionan únicamente los vectores de entrada, y ésta ajusta sus interconexiones basándose únicamente en sus estímulos y su propia salida. (Vera & Bustamante, 2007)

Algunas ventajas de las redes neuronales artificiales son:

- Son Sistemas Distribuidos no Lineales: Una neurona es un elemento no lineal por lo que una interconexión de ellas (red neuronal) también será no lineal. Esta

propiedad permite la simulación de sistemas no lineales que no se pueden realizar con los sistemas clásicos lineales. (Soria & Blanco, (s.f.))

- Son Sistemas Tolerantes a Fallos: Al ser un sistema distribuido, permite el fallo de algunas neuronas sin alterar significativamente la respuesta total del sistema. (Soria & Blanco, (s.f.))
- Adaptabilidad: Una red neuronal tiene la capacidad de modificar sus parámetros iniciales de acuerdo con los cambios que se produzcan en su entorno de trabajo. (Soria & Blanco, (s.f.))
- Establecen Relaciones no Lineales Entre Datos: Son capaces de relacionar dos conjuntos de datos mediante relaciones complejas. (Soria & Blanco, (s.f.))
- Aprendizaje Adaptativo: Es la capacidad que tienen las redes neuronales de aprender a realizar tareas basadas en un entrenamiento o una experiencia inicial. (Daza, (s.f.))
- Autoorganización: Las redes neuronales usan su capacidad de aprendizaje adaptativo para organizar toda la información que reciben durante el aprendizaje y la operación. Esta autoorganización les permite responder acertadamente cuando se les presentan datos o situaciones a los que no habían sido expuestas anteriormente. (Daza, (s.f.))
- Fácil Inserción Dentro de la Tecnología Existente: “Debido a que una red puede ser rápidamente entrenada, comprobada, verificada y trasladada a una implementación hardware de bajo costo, es fácil insertar RNA para aplicaciones específicas dentro de sistemas existentes. De esta manera, las redes neuronales se pueden utilizar para mejorar sistemas de forma incremental, y cada paso puede ser evaluado antes de acometer un desarrollo más amplio.” (Daza, (s.f.))

3.2. Lógica Difusa

La lógica Difusa es un formalismo matemático que pretende imitar la habilidad que tienen algunas personas de tomar decisiones acertadas a partir de un conjunto de datos que están expresados lingüísticamente de forma imprecisa, casi siempre utilizando adverbios o adjetivos como mucho, poco, alto, bajo, normal, muy, etc. (Hernandez, 2003) Por ejemplo, un Senior broker puede tomar una decisión correcta en el mercado

de valores y un doctor con mucha experiencia puede diagnosticar una enfermedad a partir de síndromes y síntomas.

Para entender mejor el concepto de Lógica Difusa, a continuación se presenta un ejemplo: “Según la teoría de lógica el conjunto de hombres altos solo pertenecen los que miden más de una determinada altura y esa altura límite es 1.80 metros, así un hombre es considerado alto cuando mide por ejemplo 1.81 metros y uno bajo cuando mide 1.79 metros. Esto no parece una razón muy lógica para catalogar a un hombre de alto o bajo ya que por ejemplo en el caso expuesto la altura de uno a otro solo se diferencia en 2 centímetros. Ahí, en casos como este donde no es fácil catalogar algo, se introduce la Lógica Borrosa ([Lógica Borrosa es otro nombre que se le da a la Lógica Difusa]). Según la lógica borrosa, el conjunto de “hombres altos” es un conjunto que no tiene una frontera clara que indique que perteneces a ese grupo o no. El evaluar si un hombre es alto o bajo, se hace mediante una función que define la transición entre alto a bajo y para ello asigna a las distintas alturas un valor entre 0 y 1. Según sea este valor se considera que se pertenece al conjunto o no. Aplicando esto al caso anterior, un hombre que mida 1.79 metros se puede decir que pertenece al conjunto de hombres altos con un grado de 0.75 y el hombre que medía 1.81 metros pertenece al conjunto de hombres altos con un grado de 0.8. Si representamos esto en una gráfica se obtendrá que la transición entre alto o bajo con la lógica borrosa es una curva con cambios no abruptos mientras que con la lógica clásica, el paso de alto a bajo o viceversa es brusco.” (Tamara & Durán, (s.f.))

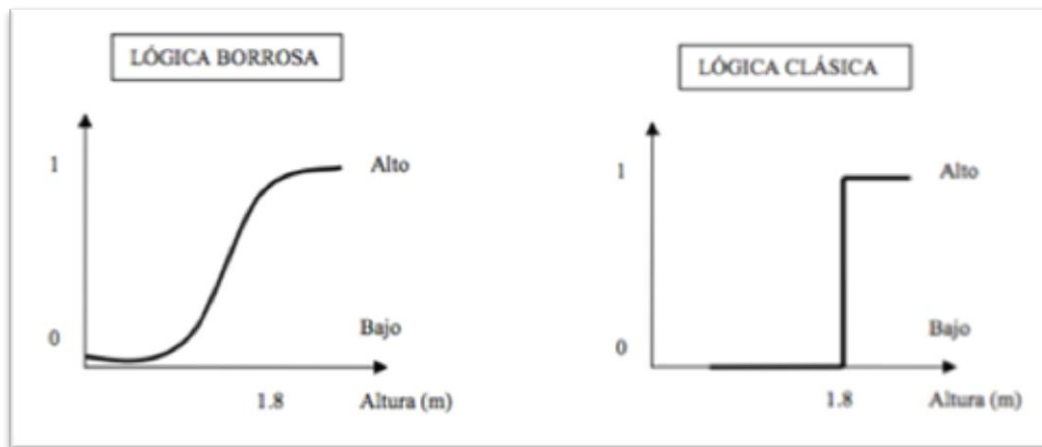


Figura 3: Lógica Borrosa vs. Lógica Clásica. (Tamara & Durán, (s.f.))

De acuerdo con Hernández, 2003, la Lógica Difusa tiene las siguientes ventajas:

- Eficiencia y rapidez en la implementación, brindando una metodología que aprovecha la experiencia de un experto.
- Es exitosa en los casos en que los datos de entrada por su propia naturaleza son escasos, imprecisos o ruidosos.
- Hace innecesario modelar detalladamente el sistema que se pretende controlar o predecir, porque utiliza un método heurístico, es decir, un método que tiene la capacidad de realizar constantemente innovaciones positivas para alcanzar sus fines.
- Permite controlar sistemas con una no-linealidad muy marcada, donde las estrategias tradicionales ofrecen resultados muy pobres.

“Estos sistemas pueden ser aplicados a similares problemas que las redes neuronales, resultando especialmente interesante para problemas no lineales o bien no definidos. De la misma manera, los sistemas borrosos permiten modelar cualquier proceso no lineal, y aprender de los datos haciendo uso de determinados algoritmos de aprendizaje. No obstante, a diferencia de las redes neuronales, los basados en lógica borrosa permiten utilizar fácilmente el conocimiento de los expertos en un tema, bien directamente, bien como punto de partida para optimización automática, al formalizar el conocimiento a veces ambiguo de un experto de forma realizable. Además, gracias a la simplicidad de

los cálculos necesarios, normalmente pueden realizarse en sistemas baratos y rápidos.”
(Tamara & Durán, (s.f.))

3.3. Sistemas Expertos

“Antes de la aparición del ordenador, el hombre ya se preguntaba si se le arrebataría el privilegio de razonar y pensar. En la actualidad existe un campo dentro de la inteligencia artificial al que se le atribuye esa facultad: el de los sistemas expertos (SE). Estos sistemas también son conocidos como Sistemas Basados en Conocimiento, los cuales permiten la creación de máquinas que razonan como el hombre, restringiéndose a un espacio de conocimientos limitado. En teoría pueden razonar siguiendo los pasos que seguiría un experto humano (médico, analista, empresario, etc.) para resolver un problema concreto. Este tipo de modelos de conocimiento por ordenador ofrece un extenso campo de posibilidades en resolución de problemas y en aprendizaje. Su uso se extenderá ampliamente en el futuro, debido a su importante impacto sobre los negocios y la industria.” (Montero, 2010)

De acuerdo con Montero, 2010, todos los Sistemas Expertos tienen una arquitectura básica que es la siguiente:

- Base de Conocimientos: Es la parte del Sistema Experto en donde está codificado el conocimiento del experto. El conocimiento se representa a través de reglas que relacionan lógicamente la información contenida en la parte del antecedente con otra información contenida en la parte del consecuente.
- Base de Hechos: Durante una consulta al Sistema Experto, el usuario introduce la información del problema actual en la base de hechos. El sistema empareja esta información con el conocimiento disponible en la base de conocimientos para deducir nuevos hechos.
- Motor de Inferencia: Es el módulo que modela el proceso de razonamiento humano, contrasta la información contenida en la base de conocimientos y la base de hechos para obtener conclusiones acerca del problema.
- Subsistema de Explicación: Proporciona explicaciones al usuario de por qué está haciendo una pregunta y cómo ha llegado a una conclusión. Este módulo

proporciona beneficios tanto al diseñador del sistema para detectar errores como al usuario que se beneficia de la transparencia del sistema.

- Interfaz de Usuario: Es la interacción entre un Sistema Experto y un usuario, a través de un lenguaje natural. También es altamente interactiva y sigue el patrón de la conversación entre seres humanos.

La principal ventaja de los Sistemas Expertos es que tienen la capacidad de trabajar con grandes cantidades de información. Un analista humano puede omitir datos que no le parezcan relevantes afectando negativamente la toma de decisiones, mientras que un Sistema Experto debido a su gran velocidad de proceso analiza toda la información incluyendo la no útil y esto le permite aportar una decisión más sólida. (Montero, 2010)

3.4. Algoritmos Genéticos

Los Algoritmos Genéticos son una técnica que imita los principios de selección natural y supervivencia de los más fuertes, postulados por Darwin. De acuerdo con esos principios, los individuos más aptos de una población son los que sobreviven, al adaptarse más fácilmente a los cambios que se producen en su entorno. (Alfaro, (s.f.)) “Hoy en día se sabe que estos cambios se efectúan en los genes de un individuo (unidad básica de codificación de cada uno de los atributos de un ser vivo), y que sus atributos más deseables (los que le permiten adaptarse mejor a su entorno) se transmiten a sus descendientes cuando éste se reproduce sexualmente.” (Alfaro, (s.f.))

Los Algoritmos Genéticos son métodos adaptativos que se usan generalmente para resolver problemas de búsqueda y optimización. Su objetivo principal es tomar soluciones existentes para problemas del mundo real y evolucionarlas para obtener nuevas soluciones que sean mejores que las anteriores. La evolución de las soluciones depende en buena medida de una adecuada codificación de las mismas. (Alfaro, (s.f.))

De acuerdo con Lazalde, 2002, los modelos de Algoritmos Genéticos funcionan de la siguiente forma:

- Inicialización: Se crean diferentes soluciones aleatorias válidas, es decir, la población inicial, los genes.
- Selección: Se eligen las mejores soluciones de la población inicial en función de un criterio y las peores soluciones son remplazadas.
- Reproducción: Se genera una segunda población o siguiente generación de la población. Esto con ayuda de dos operaciones de inspiración evolutiva: cruce y mutación. En la cruce se mezclan soluciones (los genes). En la mutación se modifican ligeramente uno o más miembros de la población de soluciones.
- Terminación: Se repiten los pasos anteriores hasta que se alcance la mejor solución posible.

De acuerdo con Alfaro, (s.f.), algunas ventajas de estos son las siguientes:

- No necesitan conocimientos específicos sobre el problema a resolver.
- Operan de forma simultánea con varias soluciones, en lugar de trabajar de forma secuencial como lo hacen las demás técnicas tradicionales.
- Cuando se usan para problemas de optimización resultan menos afectados por las falsas soluciones que las técnicas tradicionales.

4. APLICACIONES DE LOS MÉTODOS DE INTELIGENCIA ARTIFICIAL

Son muchos los estudios y aplicaciones que se han obtenido con el desarrollo de los Métodos de Inteligencia Artificial. Sin embargo, en los países menos desarrollados no han tenido una aplicación tan amplia ya que se requiere de una importante inversión en tecnología e investigación. A continuación, se presentan algunos casos desarrollados en donde estos métodos han sido utilizados con éxito y han demostrado resultados que los métodos clásicos.

4.1. Redes Neuronales para pronosticar el PIB de Colombia:

José Mauricio Salazar en su trabajo “Evaluación de Pronóstico de una Red Neuronal Sobre el PIB en Colombia” para Borradores de Economía del Banco de la República, muestra como se aplican las redes neuronales al pronóstico del PIB en Colombia llegando a las siguientes conclusiones:

- “La aplicación de las redes neuronales artificiales sobre el PIB en Colombia muestra que esta variable contiene relaciones no lineales en su proceso generador de datos y que, además, las redes logran capturar estas relaciones de manera exitosa. Se concluye esto debido a que las redes neuronales superan ampliamente al modelo lineal ARIMA. Sin embargo, dado que las redes neuronales son conocidas como modelos de “cajas negras”, no es posible identificar la fuente de las relaciones no lineales presentes en el PIB. (Salazar J. M., 2009)
- “Los modelos son considerados: dos autoregresivos (especificación lineal y no lineal) y una red neuronal que usa la tasa de interés. Evaluando el desempeño de los modelos dentro y fuera de muestra, los pronósticos realizados por las redes neuronales artificiales superan ampliamente a los modelos lineales, siendo esta evidencia de relaciones asimétricas en el comportamiento del PIB en Colombia.” (Salazar J. M., 2009)

4.2. Redes Neuronales para pronosticar el IGBC:

Una de las formas en que se mide el comportamiento de la economía de un país, es a través de las bolsas de valores locales. En Colombia el indicador más antiguo y más utilizado para medir el comportamiento económico de la Bolsa de valores es el IGBC. Actualmente, se están utilizando las Redes Neuronales para pronosticar este indicador, porque brindan a los inversionistas la posibilidad de proyectar el comportamiento del mercado bursátil de una forma muy eficiente. (Cruz, Restrepo, & Medina, 2009)

Eduardo Arturo Cruz, Jorge Hernán Restrepo y Pedro Medina, en su artículo “Pronostico del índice General de la Bolsa de Valores de Colombia Usando Redes Neuronales” para la revista Scientia et echnica de la Universidad Tecnológica de Pereira, llegaron a las siguientes conclusiones después de usar el modelo de redes neuronales para predecir el IGBC:

- “Las redes neuronales artificiales tienen una aplicación práctica en el mercado bursátil sobre los modelos estadísticos tradicionales porque no dependen de supuestos teóricos sobre los que se basan las técnicas estadísticas (normalidad, homoscedasticidad, independencia, etc.).” (Cruz, Restrepo, & Medina, 2009)
- “Los resultados y las pruebas de bondad y ajuste representados por R^2 , indican que el modelo basado en RNA es mejor que los modelos tradicionales de tendencia o crecimiento y en muchos casos a los modelos ARIMA y Garch.” (Cruz, Restrepo, & Medina, 2009)
- “El modelo propuesto se puede utilizar como parte integral de la operación financiera ya que se cuenta con herramientas computacionales especializadas para RNA y su aplicación en la toma de decisiones financieras en el manejo de la tesorería y gestión de riesgos financieros y de mercado.” (Cruz, Restrepo, & Medina, 2009)

4.3. Redes Neuronales para pronosticar la demanda:

“Por muchos años, este tipo de análisis ha estado dominado por la utilización de modelos estadísticos lineales que se pueden implementar de manera conveniente, sin embargo, la existencia de relaciones no lineales entre los datos pueden limitar la aplicación de estos modelos. En la práctica es muy posible encontrar relaciones no

lineales en los datos. Por ello es necesaria la utilización de técnicas capaces de reflejar dicho comportamiento.” (Salazar & Cabrera, 2007)

María Angélica Salazar y Mauricio Cabrera aplicaron las Redes Neuronales al pronóstico de la demanda. Su trabajo consistió en colaborarle a una empresa de telecomunicaciones que tenía la necesidad de planear a nivel operacional, estratégico y tático para mantenerse competitiva ante las fluctuaciones del mercado y cursos de acción de sus competidores.

La empresa brindó información histórica de registros mensuales acerca de la utilización de la red de transmisión de los últimos años. Con esta información, se realizó el pronóstico de la capacidad suficiente que debía tener la red de transmisión para satisfacer la demanda de los clientes en períodos posteriores mediante el uso de RNAs.

Al contrastar los resultados obtenidos mediante las RNAs con los resultados obtenidos a través de métodos clásicos. Salazar & Cabrera, en su artículo “Pronóstico de demanda por medio de redes neuronales artificiales” para la revista Ingenierías dicen lo siguiente:

“Los resultados obtenidos fueron comparados con los que se obtuvieron al analizar las mismas series de tiempo a través de métodos lineales tradicionales, tales como promedios móviles y regresión lineal, entre otros. En los casos analizados el modelo de RNAs construido con la metodología propuesta resultó con mejores resultados, quedando así como una opción viable para la aplicación en la compañía.” (Salazar & Cabrera, 2007)

4.4. Lógica Difusa para pronosticar los niveles medios diarios del río Magdalena:

El IDEAM, Instituto de Hidrología, Meteorología y Estudios Ambientales de Colombia presenta diariamente reportes de los niveles medios del río Magdalena de la siguiente forma:

- El nivel del río Magdalena en la parte alta y media registra fluctuaciones moderadas en los niveles con tendencia leve al descenso, y en la cuenca baja, registra una tendencia continua al ascenso, los valores en el rango alto.
- En Puerto Salgar, el nivel del río Magdalena presenta moderado descenso, con valores en el rango alto.

En los ejemplos anteriores se puede identificar que “l pronóstico de niveles diarios de ríos en Colombia se reporta oficialmente en términos lingüísticos. Este hecho inspiró un modelo basado en la teoría de conjuntos difusos, concepto proveniente de la inteligencia artificial. Un Sistema de Lógica Difusa (SLD) permite analizar observaciones en el tiempo clasificándolas en categorías lingüísticas, aproximadas a la calificación empleada o a la manera en que una persona describiría el fenómeno. Usando juicios de expertos se estima el nivel del día siguiente. (Segura & Obregon, 2005)

Según John Alexander Segura y Nelson Obregón, los pronósticos obtenidos con el modelo innovador de Lógica Difusa fueron muy acertados. La serie simulada con el modelo de Lógica difusa, luce muy similar a la serie real obtenida. (Segura & Obregon, 2005)

4.5. Lógica Difusa para pronosticar la demanda:

Elías Neftalí Escobar, Juan José Díaz y León Fernando Taracera, implementaron un modelo de Lógica Difusa a una embotelladora de bebidas carbonatadas para obtener un pronóstico más confiable de la demanda.

“En esta investigación la implementación de lógica difusa permite modelar la incertidumbre de la demanda del mercado a través de tres variables lingüísticas: temporada, percepción del cliente y competencia, determinando un ajuste para el pronóstico de la demanda del mercado, y así obtener una proyección que sea representativa del escenario de la empresa.” (Escobar, Díaz, & Taracena, 2010)

“El modelo descrito provee una buena herramienta para los administradores de las empresas, con proyecciones de la demanda del mercado más asertivos y un alto nivel de servicio. Sin embargo, es conveniente mencionar que los que participen en la definición de los parámetros y de los valores de entrada deben ser expertos en el comportamiento de las variables difusas.” (Escobar, Díaz, & Taracena, 2010)

“Además, esta investigación da la pauta para que en futuros proyectos se aplique lógica neurodifusa para la optimización de los parámetros de las variables difusas, de manera que se obtengan mejores proyecciones de la demanda agregada. Finalmente, al tener un pronóstico más confiable se facilita para tomar mejores decisiones.” (Escobar, Díaz, & Taracena, 2010)

4.6. Sistemas Expertos para pronosticar la demanda:

En una investigación realizada por Raúl Vilcahuamán, Iván Medina y Antonio Trelles se propone un modelo de pronóstico de demanda basado en un Sistema Experto para planificar un sistema eléctrico de potencia ya sea en transmisión o distribución.

Para realizar el pronóstico se desarrolló un software denominado PRONOS que consta de tres módulos principales:

- “La metodología propuesta permite el pronóstico de carga en los puntos de compra de las empresas eléctricas, el pronóstico brinda como respuesta el pronóstico de carga para cualquier día en el futuro (Lunes, martes, miércoles, jueves, viernes, sábado, domingo) con un perfil horario.” (Vilcahuamán, Medina, & Trelles, (s.f.))
- “El segundo módulo de PRONOS permite una caracterización de carga el cual es importante para realizar una adecuada gestión de la demanda, DMS Demand Management System y EMS Energy Management System.” (Vilcahuamán, Medina, & Trelles, (s.f.))
- “El tercer módulo permite realizar consultas respecto a valores históricos registrados, factor de carga, factor de simultaneidad, factor de coincidencia, D_{max} , D_{min} , etc.” (Vilcahuamán, Medina, & Trelles, (s.f.))

“La metodología presentada permite gestionar gran volumen de datos y generar reportes para su utilización en flujos de potencia, planificación y programas de expansión óptima y cálculo de los costos marginales de sistema eléctricos de potencia.” (Vilcahuamán, Medina, & Trelles, (s.f.))

4.7. Algoritmos Genéticos para pronosticar el rendimiento futuro de acciones:

Adam Marczyk en su artículo Algoritmos Genéticos y Computación Evolutiva explica como Mahfoud y Mani utilizaron los Algoritmos Genéticos para pronosticar el rendimiento futuro de acciones. “Mahfoud y Mani utilizaron un algoritmo genético para predecir el rendimiento futuro de 1.600 acciones ofertadas públicamente. Concretamente, al AG se le asignó la tarea de predecir el beneficio relativo de cada acción, definido como el beneficio de esa acción menos el beneficio medio de las 1.600 acciones a lo largo del periodo de tiempo en cuestión, 12 semanas (un cuarto del calendario) en el futuro. Como entrada, al AG se le proporcionaron datos históricos de cada acción en forma de una lista de 15 atributos, como la relación precio-beneficio y el ritmo de crecimiento, medidos en varios puntos del tiempo pasado; se le pidió al AG que evolucionara un conjunto de reglas si/entonces para clasificar cada acción y proporcionar, como salida, una recomendación sobre qué hacer con respecto a la acción (comprar, vender o ninguna predicción) y un pronóstico numérico del beneficio relativo. Los resultados del AG fueron comparados con los de un sistema establecido, basado en una red neuronal, que los autores habían estado utilizando para pronosticar los precios de las acciones y administrar las carteras de valores durante tres años. Por supuesto, el mercado de valores es un sistema extremadamente ruidoso y no lineal, y ningún mecanismo predictivo puede ser correcto el 100% del tiempo; el reto consiste en encontrar un predictor que sea preciso más de la mitad de las veces.” (Marczyk, 2004)

“En el experimento, el AG y la red neuronal hicieron pronósticos al final de la semana para cada una de las 1.600 acciones, durante doce semanas consecutivas. Doce semanas después de cada predicción, se comparó el rendimiento verdadero con el beneficio relativo predicho. Globalmente, el AG superó significativamente a la red neuronal: en una ejecución de prueba, el AG predijo correctamente la dirección de una acción el

47,6% de las veces, no hizo predicción el 45,8% de las veces y realizó una predicción incorrecta sólo un 6.6% de las veces, una precisión predictiva total de un 87,8%. Aunque la red neuronal realizó predicciones precisas más a menudo, también hizo predicciones erróneas más a menudo (de hecho, los autores especulan que la mayor capacidad del AG para no realizar predicciones cuando los datos eran dudosos fue un factor de su éxito; la red neuronal siempre produce una predicción a menos que sea restringida explícitamente por el programador).” (Marczyk, 2004)

CONCLUSIÓN

Desde la antigüedad contar con información sobre el futuro y poder anticiparse a este, se ha convertido en una necesidad. Las personas toman decisiones y escogen la mejor opción posible de acuerdo con la información que tienen disponible para tal efecto. Así, mientras se generen mejores pronósticos, se podrán tomar mejores decisiones.

Como se mencionó anteriormente, en los últimos años se ha producido un importante avance en el desarrollo de técnicas inteligentes para pronosticar. Ejemplos de estas nuevas técnicas son las redes Neuronales, la Lógica Difusa, los Sistemas Expertos y los Algoritmos Genéticos. Este conjunto de técnicas permiten desarrollar modelos más potentes y flexibles, y están siendo aplicadas en diversos ámbitos mostrando ser más eficientes que las técnicas clásicas cualitativas y cuantitativas; este hecho se pone de manifiesto especialmente en problemas complejos no lineales donde no se tiene información completa de algún modelo; estas técnicas han permitido explicar de mejor manera el comportamiento de las interrelaciones entre diferentes variables.

A modo de conclusión final es posible afirmar que no existe un modelo “ideal” que prevalezca per se sobre cualquier otro. “Para resolver problemas complejos, como los pertenecientes a un entorno industrial o a muchos otros entornos (economía y finanzas, medicina, etc.), con frecuencia la solución óptima consiste en una inteligente combinación de diversas técnicas, cada una de las cuales debe ser aplicada a aquel aspecto parcial del problema que mejor se adecue. En este sentido, tanto las redes neuronales como los sistemas borrosos se aplicarán especialmente allá donde los comportamientos no lineales sean importantes. Cuando no se posea un modelo suficientemente bueno, pero si se disponga de un amplio conjunto de ejemplos (casos experimentales), el empleo de una red neuronal puede resultar útil, y podemos dejar que mediante un proceso de entrenamiento ella misma encuentre el modelo o características más relevantes. Sin embargo, cuando se disponga de un conjunto de reglas proporcionadas por los expertos en un determinado tema, el empleo de sistemas basados en lógica borrosa puede ser tremendamente útil. No obstante, de la combinación de ambas técnicas, y de éstas con otras más clásicas (estadísticas, tratamiento de señal, etc.), son esperables resultados todavía mejores.” (Tamara & Durán, (s.f.)). No hay que

olvidar que desde antes del siglo XX los modelos estadísticos deterministas y estocásticos se han utilizado profusamente en el pronóstico de variables económicas y empresariales y aun en los actuales momentos diferentes técnicas estadísticas y econométricas se siguen utilizando como herramientas fundamentales de pronóstico.

BIBLIOGRAFÍA

- Alfaro, E. ((s.f.)). *Algoritmos Genéticos*. Recuperado el 05 de Marzo de 2012, de <http://eddyalfaro.galeon.com/geneticos.html>
- Cadena, J. B. (Diciembre de 2010). Aplicación y Alcance en la Gran Empresa Bogotana de los Métodos Lineales de Pronóstico en Logística y Finanzas. *Anteproyecto de Investigación no publicado*. Colegio de Estudios Superiores de Administración . Bogotá, Colombia.
- Chapman, S. (2006). *Planificación y control de la producción*. Mexico: Pearson Education.
- Cohen, R. ((s.f.)). *Pronósticos*. (Universidad de Buenos Aires (UBA)) Recuperado el 20 de Febrero de 2012, de <http://materias.fi.uba.ar/7628/PronosticosTexto.pdf>
- Correa, O. (14 de Agosto de 2009). *Mind de Colombia*. Recuperado el 20 de Febrero de 2012, de <http://mind.com.co/las-mejores-practicas-en-pronosticos-combinar-pronosticos-estadisticos-con-experiencia-e-intuicion/>
- Cruz, E. A., Restrepo, J. H., & Medina, P. (2009). Pronóstico del Índice General de la Bolsa de Valores de Colombia Usando Redes Neuronales. *Scientia et Technica* , XV (41), 129-134.
- Daza, S. ((s.f.)). *Redes Neuronales Artificiales: Fundamentos, Modelos y Aplicaciones*. Recuperado el 5 de Marzo de 2012, de <http://www.monografias.com/trabajos12/redneur/redneur.shtml>
- DMOZ. ((s.f.)). *Inteligencia Artificial: Una Visión General*. Recuperado el 08 de Marzo de 2012, de <http://www.scribd.com/doc/60172561/Inteligencia-Artificial>
- Escobar, E. N., Díaz, J. J., & Taracena, L. F. (2010). Modelo para el ajuste de pronósticos agregados utilizando lógica difusa . *ingeniería Investigación y Tecnología* , XI (3), 289-302.
- Hernandez, M. (2003). Alarando la Lógica Borrosa (Fuzzy Logic). *Revista Cubana de Física* , 20 (2), 135-139.
- Lazalde, A. (25 de Febrero de 2012). *Inteligencia artificial: algoritmos genéticos para seguridad informática*. Recuperado el 7 de Marzo de 2012, de <http://alt1040.com/2012/02/inteligencia-artificial-algoritmos-geneticos-para-seguridad-informatica>

- Marczyk, A. (2004). *Algoritmos Genéticos y Computación Evolutiva*. Recuperado el 8 de Marzo de 2012, de <http://the-geek.org/docs/algen/>
- Molina, A., Toro, E. M., & Garcés, A. (2005). *Ponóstico de Acciones en Bolsa de Valores Usando Técnicas Inteligentes*. Pereira.
- Montero, M. E. (2010). *Inteligencia Artificial*. Recuperado el 18 de Enero de 2012, de <http://www.scribd.com/doc/46876475/SISTEMAS-EXPERTOS>
- Salazar, J. M. (2009). Evaluación de pronóstico de una red neuronal sobre el PIB en Colombia. *Borradores de Economía* (575), 1-55.
- Salazar, M. A., & Cabrera, M. (2007). Pronóstico de demanda por medio de redes neuronales artificiales. *Ingenierías* , X (35), 6-12.
- Segura, J. A., & Obregon, N. (28 de Octubre de 2005). *Un modelo de lógica difusa y conjuntos difusos para el pronóstico de los niveles medios diarios del río Magdalena, en la estación limnigráfica de Puerto Salgar, Colombia*. Recuperado el 10 de Febrero de 2012, de <http://revistaing.uniandes.edu.co/pdf/rev22art12.pdf>
- Soria, E., & Blanco, A. ((s.f.)). *Redes Neuronales Artificiales*. Recuperado el 05 de Marzo de 2012, de http://www.acta.es/downloads/secciones_mfs/informatica_y_computacion/19023.pdf
- Tamara, M., & Durán, M. I. ((s.f.)). *Logica Borrosa*. Recuperado el 07 de Marzo de 2012, de <http://www.it.uc3m.es/jvillena/irc/practicass/08-09/10.pdf>
- Vera, M., & Bustamante, J. (25 de Marzo de 2007). Modelo Dinámico Para la Generación de Pronóstico Usando Redes Neuronales Artificiales (RNA). *Visión Gerencial* , 130-142.
- Vilcahuamán, R., Medina, I., & Trelles, A. ((s.f.)). *PRONOS: Sistema Experto para Pronostico de la Demanda*. Recuperado el 8 de Marzo de 2012, de http://www.iansa.com.pe/Paper_pronos_iansa.PDF
- Villanueva, M. ((s.f.)). *Las Redes Neuronales Artificiales y su Importancia como Herramienta en la Toma de Decisiones*. Recuperado el 05 de 03 de 2012, de http://sisbib.unmsm.edu.pe/bibvirtualdata/tesis/basic/Villanueva_EM/enPDF/Cap4.pdf