

Modelo dinámico para la generación de pronóstico usando redes neurales artificiales (RNA)

Miguel Vera¹
Juan Bustamante²

Recibido: 05/03/2007 • Revisado: 10/03/2007
Aceptado: 25/03/2007

Resumen >>

Tradicionalmente se pronostica utilizando métodos convencionales (regresión lineal, ARIMA), con su particular enfoque en los errores inherentes a cada método. La complejidad del entorno que afrontan organizaciones, sugiere el abordaje de una metodología que genere mayor precisión al momento de hacer estimaciones. El uso de máquinas de aprendizaje, en particular, de redes neurales, ha venido proliferándose debido a la masificación del uso de la computadora personal y a la aparición de herramientas de desarrollo cada vez más versátiles. Ahora bien, todo proceso que sea susceptible de ser vectorizado, puede ser abordado con éxito mediante el empleo de máquinas de aprendizaje. La construcción de un modelo dinámico para pronosticar permite alternativas de solución con niveles de incertidumbre mejores de los que suministra las técnicas convencionales. El programa que se utiliza para implementar el modelo, tiene como ventaja que no requiere conocimiento en programación por parte de los usuarios. Por tanto, es bastante sencillo introducir a los participantes en el mundo del pronóstico no convencional, con el objeto de apoyar la toma de decisiones.

Palabras clave: red neural, pronóstico, modelo dinámico, toma de decisiones

Abstract >>

Dynamic model for the prediction generation using artificial neural networks (RNA)

Traditionally it is predicted using conventional methods (lineal regression, ARIMA), with their particular approach in the inherent errors to each method. The complexity of the environment that confront organizations, suggests the boarding of a methodology that generates more precision at the moment to make estimations. The use of learning machines, in particular, of neural networks, has come being proliferated due to the PC massification and to the appearance of more and more versatile development tools. Now then, all process that is susceptible of being vectorized, it can be approached with success by means of the employment of learning machines. The construction of a dynamic model to predict allows alternatives of solution with better levels of uncertainty of those given by the conventional techniques. The program that is used to implement the pattern has an advantage because of it doesn't require programming knowledge. Therefore, it is quite simple to introduce the participants in the world of the non-conventional prediction, in order to support the decision taking process.

Key words: neural network, prediction, dynamic model, decisions making

1 Técnico Superior Universitario en Electrónica Industrial (ULA-Táchira). Licenciado en Educación Mención Matemática, Magister en Matemática Mención Educación Matemática (UNET), San Cristóbal. Profesor Investigador de la Universidad Nacional Experimental del Táchira. Miembro de las Asociaciones para el Avance de la Ciencia (ASOVAC), Sociedad Venezolana de Bioingeniería. (SOBEV) y Asociación de Profesores de la ULA (APULA).

2 Licenciado en Administración de Empresas, Universidad Bicentenario de Aragua (UBA), Maracay. Magister en Gerencia de Empresas, Mención Finanzas, Universidad Nacional Experimental del Táchira (UNET). Profesor investigador, Coordinador del programa de Emprendedores ULA-Táchira.

1. Introducción

El tema del pronóstico ha sido manejado históricamente desde el punto de vista clásico, sin embargo, haciendo uso de técnicas computacionales emergentes (pronóstico no clásico), se puede generar un modelo dinámico para la toma de decisiones conducente a establecer, por ejemplo, el volumen de materia prima para la producción futura de los rubros que componen una categoría particular de cualquier unidad económica, sin dejar de lado la experiencia del equipo gerencial. Esto se apoya en el hecho bien conocido, de que en el mundo empresarial se acostumbra a contar con diversos mecanismos de apoyo a la toma de decisiones, de forma que el equilibrio económico de las empresas no sufra el riesgo de ser desestabilizado por el conjunto de diversas y complejas variables que (de manera natural) influyen en su desempeño.

Con el propósito de dar respuesta al requerimiento de Industrias Corpañal, empresa ubicada en Guarenas, Venezuela, sobre la generación de un modelo que permita guiar la toma de decisiones sobre el volumen de materia prima que debe adquirirse para producir determinado producto, se trabajó —en la generación del citado modelo— no con todas las categorías sino con una particular denominada *Protección Infantil*. Esto —evidentemente— no es restrictivo sino que permitió obtener una estructura que podría incluso ser extrapolada a las otras categorías con los cambios que ello amerite.

Es importante destacar que la mencionada Industria, posee entre sus categorías la *Línea Familia* compuesta por Papel Higiénico, Servilletas, entre otros; mientras que —en la actualidad— los productos que conforman la categoría *Protección Infantil* son Pañales

Consentido, Pañales Consentido Relax y Pañales Consentido Mío. De acuerdo a la información suministrada por la mencionada empresa, los Pañales constituyen el 42% en volumen de producción y el 52% de valor económico global. Por esta razón, es que se tiene previsto trabajar con la citada categoría.

El modelo dinámico obtenido permite pronosticar, estimar o predecir los niveles de venta de la categoría seleccionada, constituyéndose en un recurso muy significativo e importante para al cuadro gerencial de la mencionada empresa, posibilitando la elección adecuada de los volúmenes de materia prima que deben ser adquiridos para abastecer los referidos niveles de venta. Por ejemplo, con base en la información que se obtenga del modelo, se pueden hacer inversiones hoy que permitan enfrentar con mayor éxito la creciente inflación, y el clima de inestabilidad económico político y social que se está previendo para los años venideros en el espectro financiero venezolano.

2. Desarrollo

2.1. ¿Qué es pronóstico?

El pronóstico es la estimación anticipada del valor de una variable, en un lapso de tiempo determinado (Hanke y Arthur, 1996). Por ejemplo, la demanda de un producto durante el 2007. En atención a ello, se puede afirmar que el pronóstico no es una predicción de lo que irremediablemente pasará en el futuro, sino una información que se obtiene con cierto grado de error (dado por una probabilidad) de lo que pudiera pasar.

2.2. Clasificación del pronóstico

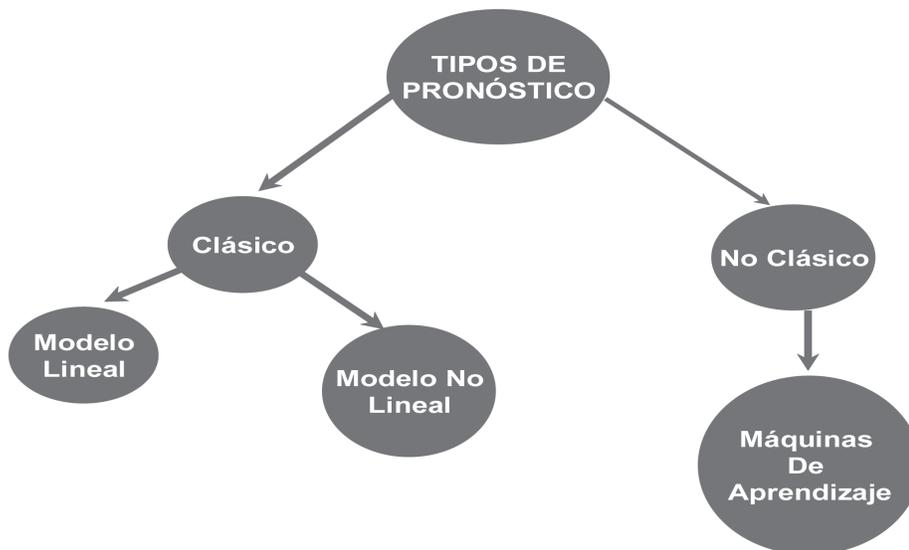
El Cuadro 1, presenta una posible clasificación de los pronósticos tomando en consideración diversos criterios.

Cuadro 1 >>>
Clasificación del Pronóstico

Por su plazo	<ul style="list-style-type: none"> ▪ Corto ▪ Mediano ▪ Largo
Según el procedimiento empleado	<ul style="list-style-type: none"> ▪ Cualitativo ▪ Cuantitativo
Método	<ul style="list-style-type: none"> ▪ Clásico ▪ No clásico
Según el entorno a pronosticar	<ul style="list-style-type: none"> ▪ Micro ▪ Macro

Para efectos del presente trabajo, se desarrollará la clasificación referida a los métodos clásicos y no clásicos puesto que se busca establecer cuál de las formas de hacer pronóstico es más eficiente. La Figura 2, presenta una ampliación de la mencionada clasificación.

Figura 2
Clasificación del pronóstico de acuerdo al criterio clásico y no clásico



En atención a dicha clasificación y para dar respuesta al requerimiento de la Empresa denominada Industrias Corpañal, se desarrolló la predicción utilizando técnicas de pronóstico clásico (en sus versiones lineal y no lineal) y pronóstico no clásico empleando como técnica emergente una máquina de aprendizaje denominada Red Neural Artificial (RNA). A continuación se presentan las generalidades de ambas técnicas.

2.3. Generalidades de algunas técnicas clásicas

Regresión lineal múltiple. La regresión lineal múltiple comprende el uso de más de una variable independiente para pronosticar una variable dependiente. En la regresión simple, la variable dependiente se puede representar por Y y la variable independiente mediante X. En el análisis de regresión múltiple se utilizan X con subíndices para representar las variables independientes (Pindyck y Rubinfeld, 1998). La variable dependiente se continúa representando con Y, y las variables independientes se representan como X₂, X₃,... X_n. Para la estimación a través de regresión lineal múltiple, el modelo se representa así:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_n X_n + \varepsilon \quad \text{Ec. 1}$$

En el modelo lineal de regresión múltiple se supone:

Linealidad en los parámetros ($\beta_0, \beta_1, \dots, \beta_n$ constantes)

Existencia de ε : Término de error o perturbación inobservable que representa los factores que influyen en Y además de X, el componente aleatorio de Y que no viene explicado por las X's.

Ninguna de las variables X₁, X₂,... X_k es constante ni existe una relación lineal exacta entre ellas W Ausencia de Multicolinealidad exacta

Regresión exponencial. Cuando dos o más variables crecen o decrecen en forma de progresión geométrica, se adoptará una función exponencial. La ecuación general es:

$$y = ae^{bx} \quad \text{Ec. 2}$$

La cual se reduce al de la función lineal cuando trabajamos con logaritmos, ya sea neperianos o con base 10. La ecuación linealizada es:

Ec. 3

Al añadir potencias de X., aumentamos la flexibilidad del modelo; casos particulares:

P2 = regresión cuadrática

P3 = Regresión cúbica

Su ecuación general es:

$$Y = ax + bx + cx + d \quad \text{Ec. 4}$$

2.4. Generalidades sobre redes neurales artificiales

Las Redes Neuronales Artificiales (RNA) han sido aplicadas a un creciente número de problemas con una complejidad considerable, como puede ser el reconocimiento de patrones, clasificación de datos, predicciones, etc. Su ventaja más importante está en solucionar problemas que son demasiado complejos para las técnicas convencionales. Para efectos de la presente investigación, las referidas redes serán utilizadas estrictamente para realizar predicciones o pronóstico. A continuación se describen elementos generales que deben considerarse al momento de abordar un problema con RNA.

Ningún computador convencional, por muy especiales que sean sus características, ha sido capaz de igualar la alta complejidad con la que el

cerebro humano procesa la diversa información que recibe a través de sus múltiples sensores. El cerebro humano es mucho más lento que un microprocesador y, sin embargo, es capaz de realizar ciertas tareas de forma más eficiente que cualquier computador, entre ellas, cabe mencionar: visión, reconocimiento de patrones, toma de decisiones y control de procesos.

Esta potencia de cálculo tiene relación con las siguientes características: Complejidad, No linealidad, Paralelismo y Aprendizaje. En virtud de esto, Haykin (1999:15) afirma que una NN:

“...es un procesador de información paralelo, masivamente distribuido y construido mediante unidades procesadoras elementales (neuronas); el cual tiene una tendencia natural para almacenar conocimiento experiencial y prepararlo para su posterior uso”.

Por otra parte, el hombre siempre en su intento por imitar los procesos naturales, ha creado –durante un lapso de tiempo que ya alcanza los 60 años– diversas estructuras que procuran simular el funcionamiento del cerebro o de algunas de sus regiones, surgiendo así las redes neurales artificiales.

En la literatura especializada, diferentes nombres han sido usados para referirse a las redes neurales, entre otros, cabe mencionar: sistemas neuromórficos, modelos conexionistas y de procesamiento paralelo distribuido (Mort, 1995). Si bien es cierto que una NN se puede implementar desde el punto de vista físico, usando dispositivos de circuito, como por ejemplo baterías, interruptores, condensadores, bobinas, resistores fijos y variables, inversores, amplificadores operacionales, entre otros; no es menos cierto que las implantadas computacionalmente son mucho más versátiles y por tanto son las que

—en la práctica— se desarrollan con mayor frecuencia (Babcock, 1996).

Es importante hacer notar, que la gran revolución impuesta por la variedad de problemas resolubles mediante el uso de las NN, ha permitido que en muchas universidades del mundo se hayan creado grupos de investigación de carácter multidisciplinario, cuya labor diaria ha permitido profundizar y/o generar nuevos aportes tanto teóricos como prácticos, no sólo en el área de la inteligencia artificial (IA) sino también en múltiples disciplinas del conocimiento humano.

Cualquier red neural está compuesta por nodos o unidades, conectados en diversas topologías de acuerdo al problema que se intente resolver. Cada conexión tiene un peso numérico asociado. Los pesos son el medio para el almacenamiento a largo plazo en una NN, y el aprendizaje se hace sobre la actualización de los citados pesos (Russell, 1997). Entre los tipos de aprendizaje se tiene:

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.

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. Las leyes de aprendizaje determinan como la red ajustará sus pesos utilizando una función de error o algún otro criterio. La ley de aprendizaje adecuada se determina en base a la naturaleza del problema que se intenta resolver (Ibídem).

Para el diseño de una NN, se deben analizar diversos aspectos de gran importancia, valiendo la pena destacar, entre otros, los siguientes:

¿Cómo codificar los patrones de entrada y salida deseada?

¿Cuál topología elegir?

¿Cuántas capas debe poseer la red?

¿Cuántas unidades o neuronas se emplearán por capa?

¿Qué algoritmo de aprendizaje implementar?

¿Cuáles funciones de activación o transferencia utilizar?

¿Cuál herramienta de programación, se debe usar para realizar las implantaciones computacionales que darán origen a la red neural requerida?

Las NN tienen dos fases de operación, ellas son:

Entrenamiento de la red. El usuario proporciona a la red un número preestablecido de patrones de entrada, y de salida deseada, la red entonces ajusta sus pesos de interconexión (sinápsis) hasta que la salida de la red esté "lo suficientemente cerca" de la salida deseada.

Recuperación de lo aprendido. A la red se le presenta un conjunto de estímulos de entrada

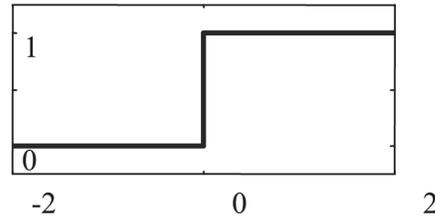
y ésta simplemente calcula su salida. Cuando la red emplea entrenamiento no supervisado, algunas veces será necesario que reajuste su sinápsis durante la fase de recuperación.

Las Redes Neurales se emplean debido a su capacidad para adaptarse o aprender, generalizar u organizar datos cuyas operaciones están basadas en procesos paralelos. Una NN no se limita a memorizar la data sobre la que ha sido entrenada, sino que posee la propiedad de *generalizar*, es decir, la red se "comporta bien" al introducirle datos no empleados durante el entrenamiento (Ibídem). Ello está relacionado con la suavidad de la función a aproximar o modelar. Para evitar el sobreentrenamiento de una red, se dividen los datos en dos conjuntos: entrenamiento-test y la red se entrena con el conjunto de entrenamiento y su capacidad de generalización se evalúa analizando el error en el conjunto de test, deteniendo el entrenamiento cuando el error del test aumenta. En NN es importante conocer las funciones de activación o de transferencia, las cuales le indican a las unidades básicas de una red neural, si entran o no en funcionamiento. Las siguientes son las funciones que se emplean (Mort, 1995).

Función escalón:

$$\varphi(x) = \begin{cases} 1, & \text{si } x \geq 0 \\ 0, & \text{si } x < 0 \end{cases} \quad \text{Ec. 5}$$

Figura 3 >>



Función signo:

$$\varphi(x) = \begin{cases} 1, & \text{si } x \geq 0 \\ -1, & \text{si } x < 0 \end{cases} \quad \text{Ec. 6.}$$

Figura 4 >>

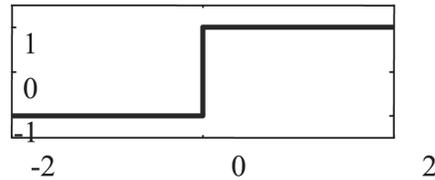
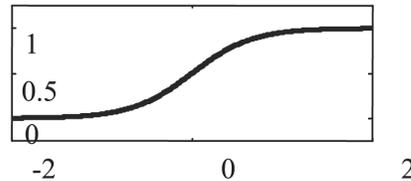


Figura 5 >>

Función sigmoide



Función sigmoide:

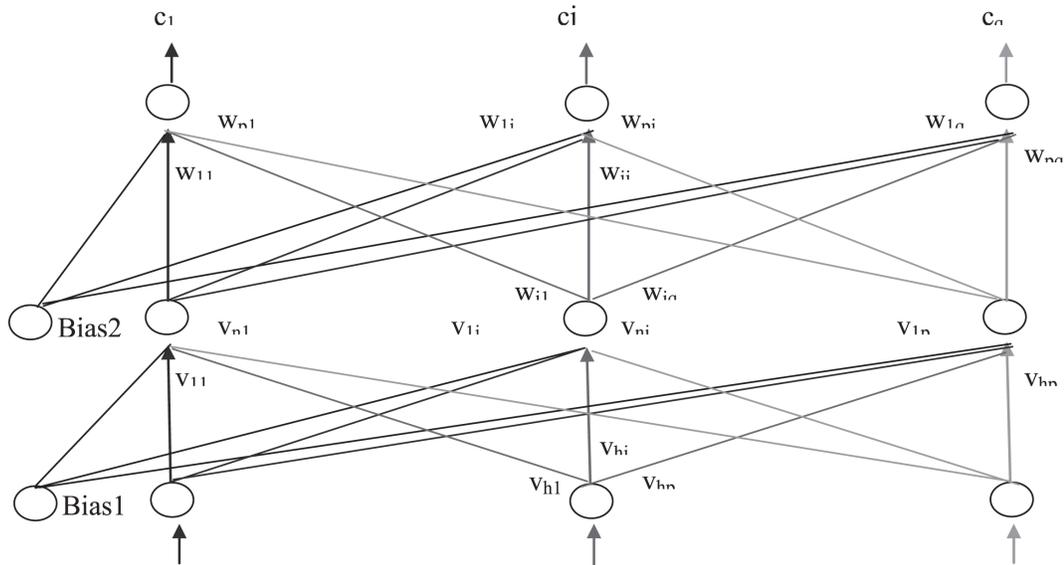
2.5. Redes multicapa alimentadas hacia adelante con algoritmo de retropropagación

La existencia de una buena cantidad de topologías y de algoritmos de aprendizaje para implementar redes neurales, hace difícil la elección de una configuración en particular. Sin embargo, uno de los factores que más influye en dicha elección lo constituye la naturaleza del problema considerado. De acuerdo a ello y en atención a las diversas pruebas realizadas, se decidió trabajar con redes multicapa alimentadas hacia adelante, con algoritmo de retropropagación. En un apartado anterior ya se describió el funcionamiento general de las

redes alimentadas hacia adelante pero no se había enfocado el fundamento matemático del algoritmo de retropropagación, aspecto éste que se desarrolla a continuación.

Una red trabajando bajo el algoritmo de retropropagación del error, está diseñada para que funcione como una red multicapa con propagación hacia adelante, empleando un aprendizaje supervisado. Para establecer el basamento matemático del algoritmo de retropropagación del error, se utilizará como referencia la figura que aparece a continuación y su notación (Coello, 2006).

Figura 6 >>>
Topología de una Red Neural



Las señales de entrada formadas por los patrones \$a_1, \dots, a_n\$, son presentadas a cada uno de los Elementos Procesadores (EP) de la capa de entrada, es decir, a los elementos \$a_1 \dots a_n\$. Estas señales son transmitidas a cada uno de los elementos procesadores de la capa siguiente (capa intermedia u oculta). En cada uno de los elementos procesadores de la capa intermedia (\$b_1 \dots b_p\$) se efectúa la multiplicación de cada una de las entradas por el peso \$V_{np}\$ correspondiente a la interconexión de la unidad \$a_n\$ a la unidad \$b_p\$, para posteriormente efectuar la sumatoria de esos productos, tal como se muestra en la ecuación 8.

$$b_p = \sum_{n1}^n V_{np} a_n \quad \text{Ec.8}$$

Una vez realizada la sumatoria, el resultado es evaluado por la función de transferencia, asignándolo a \$S_{bp}\$, así:

$$S_{bp} = f(b_p) \quad \text{Ec. 9}$$

\$S_{bp}\$ es aplicado a cada uno de los elementos de la capa de salida, es decir, los elementos (\$c_1\$

\$\dots c_q\$), en el que nuevamente se vuelve a efectuar la sumatoria del producto de estas entradas por el peso \$W_{pq}\$ tal y como se muestra en la ecuación 10.

$$c_q = \sum_{pq} W_{pq} S_{bp} \quad \text{Ec. 10}$$

El resultado anterior vuelve a ser evaluado por la función de transferencia como se muestra a continuación:

$$S_{cq} = f(c_q) \quad \text{Ec.11}$$

En donde \$S_{cq}\$ es la salida de la red para el EP en la capa \$q\$. Dicha salida es comparada contra el valor deseado para producir un error en cada EP, dicho error es calculado de la siguiente manera:

$$\text{Error} = \text{Salida_deseada} - S_{cq} \quad \text{Ec. 12}$$

Este error es propagado hacia la capa anterior (de ahí el nombre de retropropagación) en una cantidad proporcional a la influencia que haya tenido esa neurona para dar la salida deseada.

Para determinar qué fracción del error total es la que corresponde a cada EP de la capa intermedia, se emplea la desviación estándar, la cual es mostrada en su forma general en la ecuación 13.

$$\sigma^2 = \sum_{i=1}^n \varepsilon_i^2 \quad \text{Ec. 13}$$

Donde: σ =Desviación estándar; ε = Error; n = Número máximo de iteraciones

Por tanto, el error correspondiente es calculado mediante la ecuación 14

$$\text{error}_{prop} = \frac{1}{2} \sum (salida_{deseada} - S_{cq})^2 \quad \text{Ec. 14}$$

Como lo que se debe hacer es minimizar el error, entonces se emplea el método del gradiente descendente, pues los pesos forman una superficie n dimensional, en la que los pesos deben acercarse al mínimo total, para lo cual se debe derivar el error, es decir:

$$\frac{\partial \text{error}_{prop}}{\partial W_{pq}} = \frac{\partial}{\partial W_{pq}} \left[\frac{1}{2} \sum (salida_{deseada} - S_{cq})^2 \right] \quad \text{Ec. 15}$$

Cabemencionar que antes del entrenamiento, los pesos de las conexiones para cada neurona tienen un valor aleatorio, ninguna vía o ruta es favorecida. Como ya se mencionó, durante el entrenamiento las salidas de la red son comparadas contra un valor deseado, generando un error, el cual es usado para corregir la red, el algoritmo de entrenamiento es el responsable de efectuar estas correcciones por ajuste de los pesos de las conexiones en cada neurona, después de varias iteraciones. Una vez que ya se considera la red entrenada, algunas de las rutas de conexiones tienen mayor importancia que otras, lo que nos permite llegar a obtener una respuesta correcta.

Ahora bien, para agilizar el entrenamiento y lograr la convergencia de la red más rápido, lo que se hace es agregar un término denominado *Bias*, cuyo objetivo es mejorar la velocidad de convergencia de la red, lo cual permite un mejor desempeño de la misma.

De la Figura 6, se puede observar que el EP de *Bias* no recibe entrada alguna, esto es porque por definición, este EP toma un valor constante de 1.

El elemento procesador del *Bias* tiene un peso asociado a sus conexiones con los EP's de las capas siguientes. Con esto se ve que la red puede ser entrenada y que el *Bias* actúa como un factor en el resultado final lo cual hace que los pasos hacia el mínimo total a alcanzar sean mayores, reduciendo el tiempo necesario para alcanzar este punto, es decir, lograr la convergencia de la red más rápido.

De todos los tipos de funciones de entrenamiento que se conocen, se eligió trabajar con la función de retropropagación resiliente (*rbp*), debido a que diversos estudios han demostrado que cuando se trata de reconocimiento de patrones, *rbp*, tiene una mejor desempeño tanto en tiempo como en calidad de respuesta que muchos otros algoritmos de entrenamiento. El algoritmo de entrenamiento *rbp*, tiene dos ventajas adicionales: converge mucho más rápido que otros algoritmos y sus requerimientos de memoria son mínimos (mathworks, 2004).

Típicamente las redes multicapa usan funciones de transferencia sigmoidales en las capas ocultas. Estas funciones tienen la particularidad de comprimir un rango de entrada

infinito en un rango de salida finito y además su pendiente tiende a cero cuando los vectores de entrada son muy grandes. Esto ocasiona un problema de variación mínima sobre los pesos y las *Bias*, haciendo que las redes entreguen respuestas erradas debido a que convergen aún cuando sus valores no son óptimos.

Para minimizar el referido problema, rbp solamente considera el signo de las derivadas en la actualización de los pesos y las *Bias*, generando un valor de actualización (V_a) que es controlado por los parámetros del mencionado algoritmo.

Para efectos de la investigación desarrollada se usó una herramienta de desarrollo denominado Braincel que funciona embebido en Excel y que permite diseñar redes neurales artificiales de una manera interactiva y que reduce al mínimo los requerimientos de programación y que adicionalmente hace posible sortear con éxito cada uno de los elementos de diseño presentados. A continuación se hace una breve descripción de Braincel.

2.6. ¿Qué es Braincel?

Es una herramienta de desarrollo que utiliza toda la potencia de Excel para construir,

entrenar, validar y simular una red neural artificial. Es un programa que está disponible en la red de forma gratuita en www.promland.com en su versión DEMO y que puede ser adquirida en su versión profesional con un costo de 250 dólares americanos.

Una vez abierta una hoja de cálculo en Excel se abre el Braincel y se genera un menú que permite generar y trabajar de manera sencilla pero muy eficiente cualquier tipo de problema que sea susceptible de ser abordado con redes neurales artificiales. Una vez creada una red neural, se presentan las series de tiempo a su entrada, la red se encarga de analizar las posibles relaciones que se presenta entre los "históricos" y genera una salida que al ser cotejada con el error establecido previamente se toma como respuesta definitiva o no dependiendo de si se ha alcanzado el nivel deseado.

3. Resultados

A continuación, haciendo uso de la Tabla 1, se presentan los resultados obtenidos con Excel (pronóstico clásico) y Braincel (pronóstico no clásico). En la mencionada tabla se indica el tipo de técnica utilizada y el mínimo nivel de error obtenido por cada una de ellas.

Tabla 1 >>

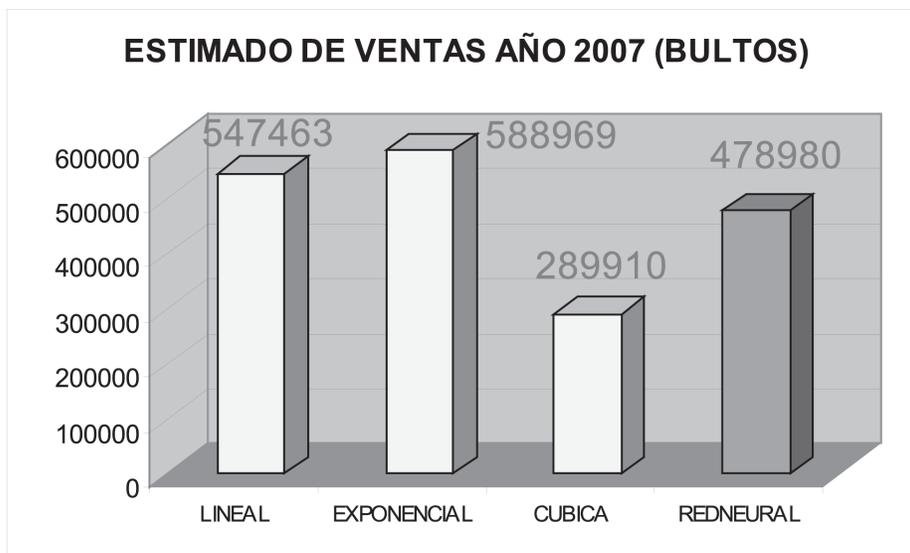
Comparación cuantitativa de los pronósticos para el año 2007, por tipo de técnica referenciada respecto al nivel de error

ESTIMADOS DE VENTA				
PRONÓSTICO 2007 CON VARIAS TÉCNICAS	LINEAL	EXPONENCIAL	CUBICA	REDNEURAL
	22%	28%	19%	5%
ENE	34742	40646	30823	26078
FEB	42747	42014	30151	22411
MAR	44662	43428	29331	28987
ABR	47651	44889	28358	46950
MAY	51924	46400	27224	41771
JUN	49019	47961	25924	43025
JUL	43182	49576	24450	32709
AGO	38999	51244	22797	46746
SEP	44484	52969	20959	44509
OCT	43531	54751	18928	43862
NOV	48661	56594	16699	45375
DIC	57861	58498	14266	56557
TOTAL BULTOS	547463	588969	289910	478980

Como se aprecia, la red neural consiguió generar un pronóstico más preciso, reduciendo el nivel de estimación a un valor muy pequeño, en relación a las técnicas clásicas, lo cual le permite al cuadro gerencial de la referida

compañía, hacer las respectivas comparaciones y tener un apoyo más eficiente para la toma de decisiones. La Figura 7 presenta el total de ventas estimadas por técnica utilizada, mediante un gráfico de barras.

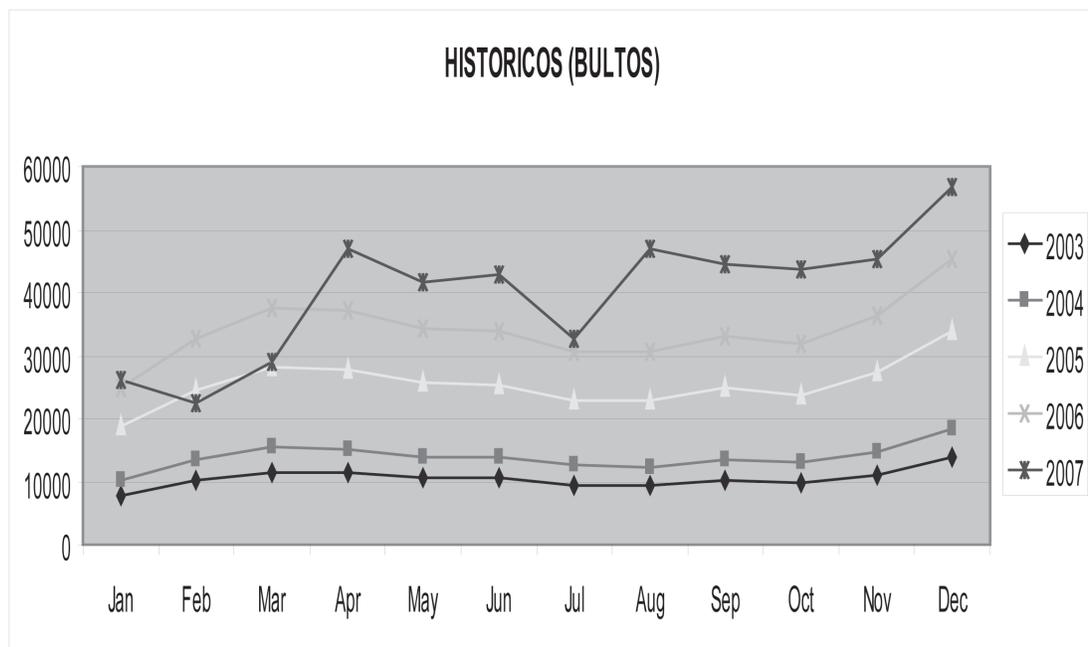
Figura N° 7 >>
Estimado de Ventas CORPAÑAL



Por otra parte, la Figura 8 permite comparar los “históricos” suministrados por CORPAÑAL y el volumen mensual de ventas estimados para la variable pronosticada, mediante el modelo dinámico desarrollado (RNA). Como dicha figura permite apreciar, se prevén picos decrecientes

en las ventas de los meses febrero y julio de 2007, lo cual podría generar alguna medida tendiente a prever acciones, desde el punto de vista de la mercadotecnia, para suavizar esos niveles que pudieran considerarse estacionales.

Figura 8 >>
Gráfico históricos



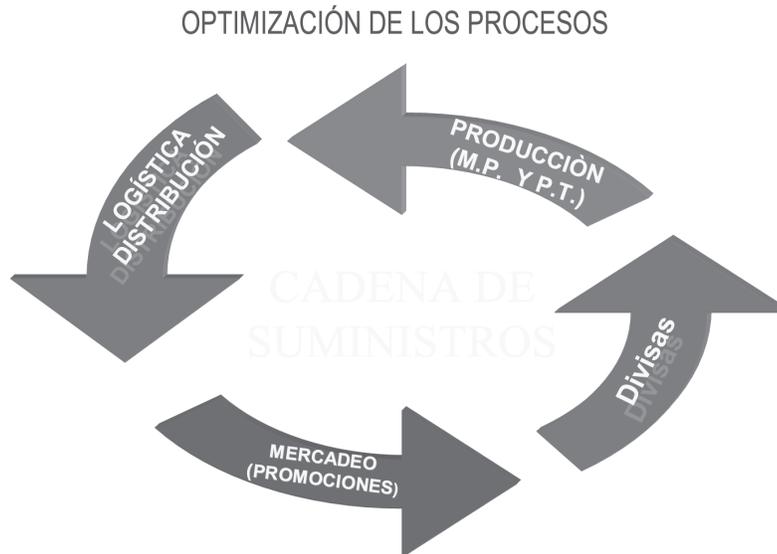
Un punto importante que los gerentes deben tener presente es el impacto en los pronósticos de la decisiones que toman y cómo logran generar mayor eficiencia en el manejo de la cadena de suministros de una organización.

Una forma de clasificar la necesidad de elaborar pronósticos en la gerencia es considerar las áreas funcionales a las cuales se refieren los pronósticos mismos (Makridakis y Wheelwright, 2006). Por ejemplo, en mercadotecnia puede mejorarse cierto número de decisiones al

fundamentarlas en predicciones confiables acerca del tamaño y las características del mercado.

En producción, la demanda del producto es el área que mayor necesidad tiene de los pronósticos. Aquí se toma necesario predecir tanto los volúmenes como la composición, de modo que la empresa pueda planificar su programa de producción y sus existencias para hacer frente a las exigencias del mercado de la mejor manera posible, tal y como lo ilustra la Figura 9.

Figura 9 >>>
Optimización de cadena de suministros



4. Conclusiones

Se logró generar un modelo dinámico para la realización de un pronóstico con un margen de error menor que el obtenido con los métodos clásicos. Por ello se puede afirmar que la utilización de redes neurales artificiales aporta soluciones más eficientes y seguras que los métodos convencionales.

Como una extensión a la presente investigación se propone explorar el pronóstico con otras máquinas de aprendizaje, entre otras, las máquinas de soporte vectorial que de acuerdo a la literatura especializada poseen múltiples ventajas sobre las RNA, ya que por ejemplo no tienen el problema de los puntos críticos locales.

Bibliografía

- BABCOCK, L. et al (1996). *Complex dynamics in simple neural circuit*. Aip CONFERENCE Proceedings 151, pp. 23-28.
- COELLO (2004). Documento en línea. Disponible en: <http://hp.fciencias.unam.mx/revista/soluciones/n17/coello2/> (Consulta: mayo 22 de 2006).
- DOCUMENTO EN LÍNEA. Disponible en: <http://www.mathworks.com/acces/helpdesk/help/toolbox/nnet/functionlist.htm/> (Consulta: agosto 21 de 2006).
- HANKE, J., REITSCH (1996). *Pronósticos en los negocios*. Quinta edición. Prentice Hall. México.
- HAYKIN, S. (1999). *Neural networks. A comprehensive foundation*. Prentice Hall. Segunda edición.
- MAKRIDAKIS, S. y WHEELWRIGHT, S. (2006). *Métodos de pronósticos*. Editorial Limusa. México
- MORT, N., et al (1995). *Neural network-based adaptative control design*. Universidad de los Andes-Mérida, Venezuela.
- PINDYCK, R., y Rubinfeld, D. (2000). *Econometría. Modelos y pronósticos*. Cuarta edición. McGraw-Hill. México.
- RUSSELL, S. et al (1997). *Artificial intelligence: a modern approach*. Prentice Hall.