



## **DIPLOMA DE POSTTULO**

**PREPARACIÓN Y EVALUACIÓN DE PROYECTOS**

**MODULO: METODOS DE ESTIMACION Y DEMANDA**

**PROFESOR: RICHARD WEBER**

**MATERIAL DOCENTE**

**- AÑO ACADEMICO 2009 -**

# → TREND → MANAGEMENT

## EN ESTA EDICIÓN

### Intraweb

#### **INTRAWEB: La Nueva "Lógica" para los Negocios Exitosos**

*Resalta las diferencias entre "tecnología y máquinas", tal como no es igual el "lenguaje y el idioma", "el estado y el gobierno" o "la mente y el cerebro".*

Por los profesores: Sergio Melnick, Ph.D. UCLA y José Miguel Barraza, MBA UAI, de la Universidad Adolfo Ibáñez.

### Gobierno Corporativo

#### **Gobierno Corporativo: Estrategia para la Creación de Valor.**

*Expone cómo maximizar el valor a largo plazo de las empresas, a través de implementar un adecuado gobierno corporativo.*

Por los profesores: Teodoro Wigodski S. y Franco Zúñiga G., de Ingeniería Industrial de la Universidad de Chile.

### Management

#### **Impacto de las Buenas Prácticas de Gestión de Empresas en una Escuela Municipalizada:**

#### **La Experiencia de la Corporación Municipal de Melipilla**

*Analiza un caso real, en que el resultado de la descentralización y privatización de una escuela rural, mejora considerablemente al aplicar técnicas de gestión moderna en su administración.*

Por los profesores: Rafael Águila, Mladen Koljatic y Mónica Silva, de la Pontificia Universidad Católica de Chile.



**Universidades Chilenas presentan sus mejores "Papers" en Management**

**Management  
made in Chile**



## Cadena de Suministro: ¿Qué necesitarán mis Clientes Mañana?

La gestión óptima de la cadena de suministro juega un rol importante para la satisfacción de los clientes, tanto en relación a los precios como a la disponibilidad de los productos.

*Por los profesores: Luis Aburto y Richard Weber,  
de Ingeniería Industrial de la Universidad de Chile.*



**Luis Aburto**, Penta Analytics, y **Richard Weber**, ambos de Ingeniería Industrial de la Universidad de Chile.

**U**n día cualquiera, usted entra a un supermercado haciendo la compra de la semana. Entre otros productos, está buscando el helado de Pie de Limón, que tanto les encanta a los niños de la casa. Pero el espacio en la góndola donde siempre encuentra el helado está vacío, ¡no hay helado con ese sabor!

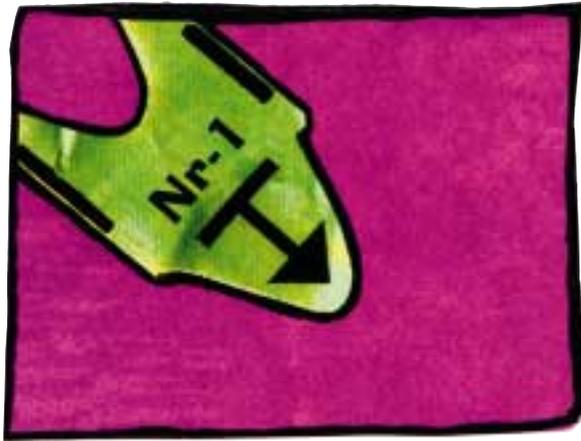
### **¿Suenan Conocido? ¿Le ha Pasado algo Similar?**

¿Qué hace? ¿Compra un helado similar? ¿No compra helado? ¿Va a la competencia para buscar “su producto”? Y en este último caso: ¿Sigue comprando en la competencia?

¿Se ha preguntado ¿por qué no había su helado favorito en la góndola? Claro: La demanda superó la oferta y se agotó el stock de este producto.

Pero: En un supermercado mediano el helado de Pie de Limón es uno de miles de productos y los clientes esperan siempre cada uno de sus productos disponible y a bajo precio.

Tener siempre todos los productos en stock no sería un problema para el supermercado; simplemente tendría que almacenar cantidades muy altas de todos los productos. Pero en este caso: ¿Cómo se ven afectados los precios? Es claro ver que los costos de capital aumentan al almacenar más



productos. Mayor es el problema cuando hablamos de los miles de ítems que manejan las cadenas de supermercados hoy en día.

Una de las grandes preocupaciones de la última década en toda la industria de Supermercados, ha sido la reducción de las mermas en la cadena de suministro. Así, el tema adquiere mayor importancia cuando los altos niveles de inventario en bodega son una de las fuentes de pérdida importantes que tienen las cadenas de supermercados.

En definitiva, este es el dilema principal del supermercado: Siempre tiene que tener todos los productos disponibles, pero solamente las cantidades necesarias para no aumentar los precios.

No solo los supermercados tienen este problema. Un pronóstico de la demanda es importante también para tiendas, para el suministro de agua, gas, bencina o productos masivos de alto valor como vehículos, repuestos, piezas para computadores, por ejemplo.

Pero no solamente las empresas donde compran los consumidores finales (por ejemplo un supermercado) quieren saber la demanda futura. Cada agente de la cadena de suministro entre la materia prima y el consumidor final tiene que tomar decisiones en base a la demanda futura de sus productos.

### Cadena de Suministro

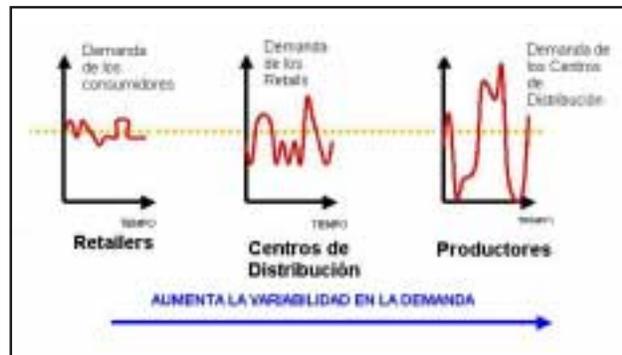
La Cadena de Suministro queda definida por el conjunto de actores que realizan el flujo físico de productos, desde fabricantes hasta los consumidores finales. Para decidir cuánto comprar, con qué frecuencia comprar, qué productos comprar, las empresas de retail (y en particular los supermercados) deben usar el flujo de datos que se genera a partir de los consumidores. En otras palabras, usando la información de la demanda que enfrenta cada agente de la cadena (Retailers, Centros de Distribución, Productores y Proveedores) se deben tomar decisiones respecto del flujo de productos tal como lo muestra la Figura 1.

Cadena de Suministro (figura 1)



El problema que enfrentan los demás agentes de la cadena es mucho más grave debido a que la variabilidad de la demanda es mucho mayor que en las empresas de retail (esto porque enfrentan mayor incertidumbre en su decisión). Este efecto [11] se conoce como “Efecto Látigo” (Figura 2).

Efecto Látigo en la Cadena de Suministro (figura 2)



Es claro ver que al tener mayor variabilidad en la demanda, los distintos agentes deben acumular más inventario para enfrentar posibles contingencias.

Las soluciones a este gran problema que enfrenta toda cadena de suministro pasan, por un lado, por trabajar de manera coordinada entre todos los agentes. Por otro lado, se pueden hacer mayores esfuerzos en la predicción de la demanda que enfrentan. Eso es precisamente el enfoque del presente trabajo.

### Modelos de Pronóstico – Algo de Matemáticas...

Los modelos matemáticos para resolver problemas de predicción han presentado notorios avances en los últimos 30 años. Como consecuencia la literatura científica provee muchos métodos cuantitativos para pronósticos. Este capítulo muestra algunos de los más conocidos: los modelos ARIMA y las redes neuronales. Luego se encuentra una comparación entre estos dos enfoques. Los detalles matemáticos no son necesarios para poder entender el contexto del presente trabajo, se los muestra para tener una descripción completa de la materia.

### Modelos ARIMA

El problema de predicción de series de tiempo ha sido preferentemente solucionado por el trabajo realizado con la familia de modelos ARIMA (Autoregressive Integrated Moving Average) propuesta por Box y Jenkins [4]. Se define:

- $X_t$  es la observación de una serie en el tiempo t. Cada observación  $X_t$  tiene una distribución de probabilidad  $f(X_t)$  no necesariamente i.i.d. (independiente e idénticamente distribuidos).
- A es una serie de tiempo de n observaciones "ruido blanco" con media cero y varianza  $\sigma_a^2$
- B es el operador de retraso. Ej:  $BX_t = X_{t-1}$  y  $BA_t = A_{t-1}$
- $V=1-B$  es el operador diferenciador. Ej:  $-X_t = (1-B)X_t = X_t - X_{t-1}$

El proceso ARIMA(p,d,q) está compuesto por una serie diferenciada d veces, con p términos autorregresivos y q términos de un proceso de media móvil. La ecuación queda:

$$\phi_p(B)(\nabla^d X_t - \mu) = \theta_q(B)A_t$$

El resultado de estos modelos es la constante m y los vectores de parámetros  $\theta_q$  (medias móviles) y  $\phi_p$  (autorregresivos) que mejor se ajusten a los datos.

El proceso se puede generalizar aún más al incorporar elementos estacionales. Se define el operador diferenciador estacional:  $\nabla_s = 1 - B^s$  con s, factor de estacionalidad. Además, la serie de tiempo  $X_t$  puede verse explicada por variables externas o predictores (llamados también regresores). De esta forma, el modelo más general queda definido por SARIMAX (p,d,q) (sp,sd,sq) Y, donde Y son las r variables externas del proceso.

**Finalmente, la ecuación general del modelo queda:**

$$\phi_p(B)\Phi_{sp}(B)\left[\nabla^d \nabla_s^d (X_t - \sum_{i=1}^r c_i Y_i) - \mu\right] - \theta_q(B)\Theta_{sq}(B)A_t$$

donde  $\Phi_{sp}(B)$  es el polinomio autorregresivo estacional de orden sp,  $\Theta_{sq}(B)$  es el polinomio de promedios móviles estacional de orden sq y  $c_i$  son los coeficientes de los regresores.

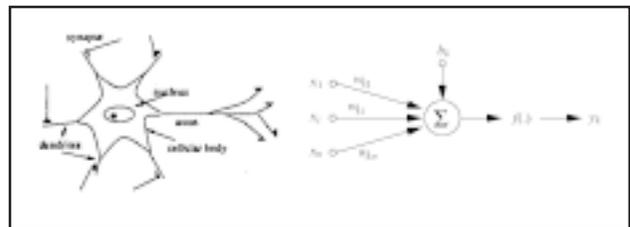
### Redes Neuronales

Una red neuronal es una red de muchas unidades (neuronas), unidas por conexiones donde cada conexión está ponderada por un peso [14]. La motivación para el desarrollo de una red neuronal es el intento de modelar matemáticamente la estructura y el funcionamiento del cerebro humano. Cada unidad de una red neuronal artificial recibe y entrega datos numéricos a través de sus conexiones. Igual que

el cerebro humano, estas redes tienen que "aprender" de la información disponible. Generalmente, las redes neuronales tienen algún tipo de regla de entrenamiento, en la cual los pesos de las conexiones son ajustados de acuerdo a los datos que recibe la red.

En otras palabras, las redes neuronales "aprenden" de los datos, y bajo ciertas condiciones exhiben la capacidad para generalizar más allá que los datos con que fueron entrenadas. Es decir, entregan resultados aproximadamente correctos para nuevos casos que no fueron usados en el entrenamiento. La figura a continuación muestra la similitud entre una neurona natural y una artificial:

**Comparación entre una Neurona Natural y una Neurona Artificial (figura 3)**



De acuerdo al gráfico se tiene que  $y = f\left(\sum_{i=1}^n w_i x_i + b_i\right)$ .

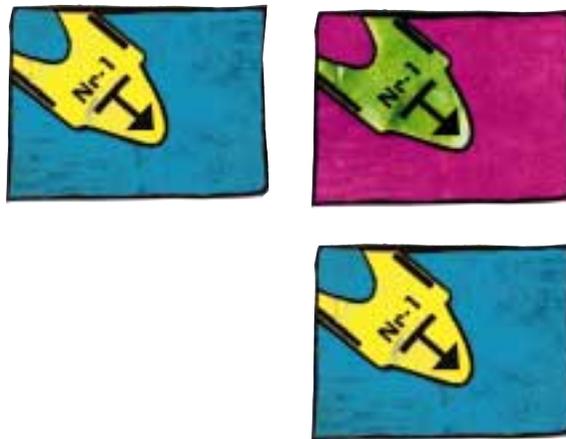
Por lo general  $f(x) = \frac{1}{1 + e^{-x}}$

El modelo más popular dentro de las redes neuronales, es el Perceptrón Multicapas (MLP) [8]. Este modelo está compuesto por varias unidades formando varias capas entre sí, y la información se pasa de una capa a la siguiente capa. Generalmente las redes MLP son entrenadas con la regla de aprendizaje llamada retropropagación (Backpropagation en inglés) del error el cual minimiza el error mediante un ajuste de los pesos de la red.

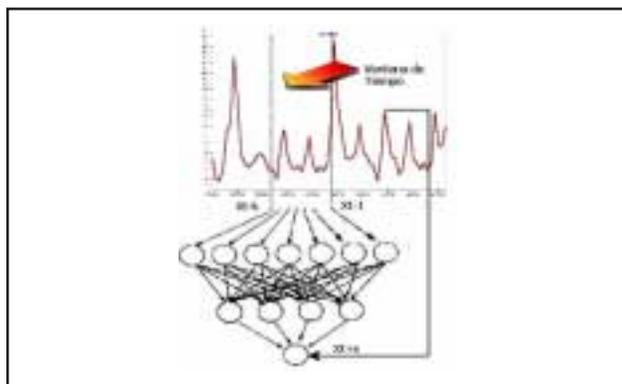


El problema de la modelación es que el proceso de aprendizaje puede degenerar en un sobreajuste del modelo a los datos, es decir, el modelo se aprende de memoria los datos recibidos, perdiendo con ello toda capacidad de generalización. Para resolver esto se evalúa el aprendizaje sobre otro conjunto llamado de testeo. Los datos de testeo no se usan para el entrenamiento de la red.

Los modelos de redes neuronales han permitido resolver diversos problemas: clasificación, optimización, agrupamiento o "clustering", y predicción o pronóstico. En este último aspecto es donde se enfocará el trabajo descrito en el presente artículo. Para el caso particular de este proyecto, se usará MLP para el pronóstico de series de tiempo. La arquitectura general usada en este tipo de problemas, es la mostrada en la Figura 4.



#### Red MLP para el Pronóstico de Series de Tiempo (figura 4)



Para la predicción de series de tiempo, ella requiere de dos parámetros. El primero de ellos es  $k$ , que indica el largo de la ventana de tiempo que se usará como patrón de entrada para predecir en el futuro la serie de tiempo. El segundo parámetro es  $s$ , que representa el número de intervalos en el futuro en que se desea predecir la serie de tiempo.

#### Comparación entre los Modelos ARIMA y Redes Neuronales

Una vez conocido ambos tipos de modelos matemáticos para el pronóstico de series de tiempo, es importante saber las ventajas que tiene una formulación sobre la otra y viceversa. Existe amplia literatura que compara ambos modelos, tanto teórica [6] [12] como empíricamente [9] [10]. A modo de resumen se presenta un cuadro comparativo entre los modelos ARIMA y MLP.

### Comparación entre los Modelos ARIMA y MLP (Tabla 1)

| Modelo Estadístico (ARIMA)  | Redes Neuronales (MLP)   |
|---|--|
| Modelo lineal: asume un comportamiento de la serie a priori           | Modelo no lineal: más grados de libertad para el modelo            |
| La modelación requiere que la serie sea estacionaria                  | No imponen requisitos estadísticos a la serie de tiempo a analizar |
| Tiene menos grados de libertad en el modelamiento de series de tiempo | Tiene más grados de libertad en el modelamiento series de tiempo   |
| Requiere de profundos conocimientos en Estadística                    | Requieren menor interacción con el usuario                         |
| El modelo entrega conocimiento e información en sus parámetros        | Difícil lectura del modelo (caja negra)                            |
| Bajo peligro de sobreajustar el modelo                                | Fácil de sobreajustar el modelo a los datos                        |

A continuación se analizará una aplicación de pronóstico con estos dos enfoques matemáticos. El pronóstico se ocupó para un producto particular de alta rotación de uno de los locales de la cadena Economax. El pronóstico construido se empleó para mejorar la administración de los inventarios en bodega del producto en estudio.

### Pronóstico de Demanda en Economax

La cadena de supermercados Economax, al igual que cualquier empresa de retail, entrega al público una amplia gama de productos de consumo (del orden de 5000 productos distintos) adquiridos a un gran número de fabricantes y distribuidores.

Para decidir cuánto comprar, con qué frecuencia comprar, qué productos comprar, la empresa debe usar el flujo de datos que se genera a partir de los consumidores. En otras palabras, usando la información que se tiene en la cadena de suministro (tiempos de reposición, ventas desagregadas, niveles de inventario y niveles de servicio deseados) se deben tomar decisiones respecto del flujo de productos desde proveedores hacia los clientes.

Para resolver el problema mencionado [1], surge la necesidad de tener un pronóstico de la demanda de los productos en la cadena de supermercados. Los modelos que resuelven el problema de la reposición de inventarios [12] han demostrado ser robustos y satisfactorios y se usarán en la construcción del sistema de reposición de productos. Sin embargo, la resolución del pronóstico de ventas para el caso de la venta en supermercados es compleja, a causa de diversos factores. De partida las ventas dependen de muchos factores, como por ejemplo:

- **Ventas pasadas**
- **Precios**
- **Campañas Publicitarias**
- **Estacionalidad**
- **Festivos**
- **Clima**
- **Venta de productos similares**
- **Promociones de la competencia**

Esta multidependencia de las ventas hace que el comportamiento de la serie de tiempo sea difícil de predecir, sobre todo en períodos de alta demanda [14]. El problema se complica aún más cuando se trata de 5000 productos a predecir en todo el supermercado. Además, los modelos utilizados preferentemente para el pronóstico (suavización exponencial y modelos ingenuos), no presentan resultados satisfactorios en este tipo de series de tiempo. Esta dificultad en el pronóstico de la venta implica errores en la predicción, generando costos no despreciables para la empresa, en el proceso de reposición de inventarios.

En la literatura existen aplicaciones de pronóstico de de-

manda que han constituido grandes ahorros de costos de inventario en las empresas donde se han aplicado. Algunos ejemplos: ICA Handlarna es una cadena de supermercados en Estocolmo, Suecia [5]. En conjunto con la Universidad de Skövde se desarrolló un modelo basado en redes neuronales, que mejoraba la predicción alrededor de un 40% en los períodos de campañas publicitarias. Otro ejemplo es el trabajo realizado por Bansal, Vadhavkar y Gupta [3], quienes disminuyeron los niveles de inventario de una empresa farmacéutica con alrededor de 1000 tiendas en un 50%, manteniendo los niveles de servicio, con un sistema de pronóstico basado en redes neuronales.



### Resultados Obtenidos en el caso de Economax

Para evaluar el desempeño de los pronósticos ( $\hat{X}_t$ ) entregados por los distintos modelos a construir, de una serie de media  $\bar{X}$  y desviación  $\sigma$ , se usarán las siguientes medidas de error:

Error Porcentual Absoluto Medio: 
$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - \hat{X}_t}{X_t} \right|$$

Error cuadrático medio normalizado: 
$$NMSE = \frac{\sum_{t=1}^n (X_t - \hat{X}_t)^2}{\sum_{t=1}^n (X_t - \bar{X})^2} = \frac{1}{n} \sum_{t=1}^n \left( \frac{X_t - \hat{X}_t}{\sigma} \right)^2$$

Para esta aplicación se ocupan los siguientes datos del producto 100595 (Aceite Vegetal 1 litro), tanto en los modelos ARIMA como en las redes neuronales:

- Ventana de tiempo con ventas históricas del producto
- Precios del producto durante esa historia, en el local y en la competencia relevante.
- Datos referentes a características diarias: feriados, fines de mes, quincena, vacaciones, entre otros.

Se usaron la herramienta computacional SPSS para los modelos ARIMA y DataEngine para las redes neuronales. Los modelos construidos se comparan con los pronósticos

que actualmente realiza el supermercado (ingenuo, ingenuo estacional, y la media incondicional de los datos).

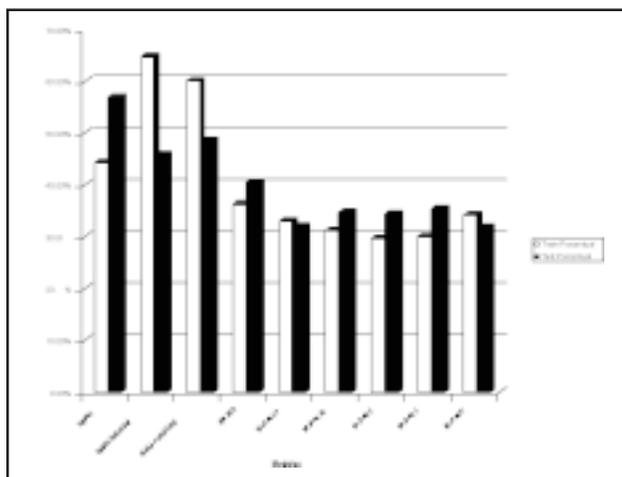
A continuación se evalúan estos enfoques comparándolos con modelos ARIMA y redes neuronales con distintos tamaños de ventanas de tiempo  $k$  (MLP-tw $k$ ). Sus desempeños son evaluados por las medidas de error NMSE (error normalizado) y MAPE (error porcentual), sobre ambos conjuntos (de entrenamiento y de testeo). Los resultados fueron los siguientes:



**Resumen de Resultados con los Diferentes Enfoques de Pronóstico para el Producto 100595 (Tabla 2)**

| 100595              | Conjunto de Entrenamiento |                   | Conjunto de Testeo |                   |
|---------------------|---------------------------|-------------------|--------------------|-------------------|
|                     | Error Porcentual          | Error Normalizado | Error Porcentual   | Error Normalizado |
| Ingenuo             | 44.26%                    | 0.6972            | 56.83%             | 1.2481            |
| Ingenuo Estacional  | 64.67%                    | 1.2212            | 45.75%             | 1.9217            |
| Media Incondicional | 59.96%                    | 0.7759            | 48.54%             | 0.9689            |
| ARIMA               | 36.21%                    | 0.3301            | 40.49%             | 0.6060            |
| MLP-tw21            | 32.93%                    | 0.4633            | 31.85%             | 0.4973            |
| MLP-tw14            | 31.15%                    | 0.3115            | 34.64%             | 0.5703            |
| MLP-tw3             | 29.61%                    | 0.3002            | 34.36%             | 0.5281            |
| MLP-tw1             | 30.00%                    | 0.3405            | 35.31%             | 0.5340            |
| MLP-tw0             | 34.12%                    | 0.4760            | 31.80%             | 0.6244            |

**Gráfico de Errores Porcentuales para el Pronóstico del Producto 100595 (figura 5)**



En el gráfico se puede apreciar la ganancia en precisión del pronóstico al usar modelos más complejos que los ingenuos. También se nota la mejora en el desempeño que tienen las redes neuronales sobre el modelo ARIMA.

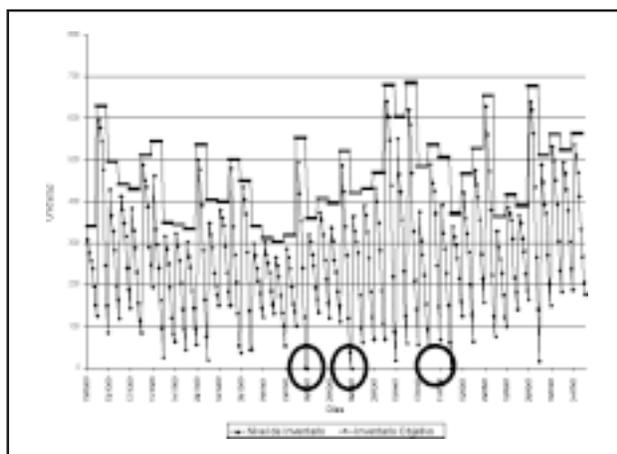
Los modelos ARIMA entregaban siempre buenas soluciones, además de la valiosa información de las variables que explicaban el fenómeno. La ventaja de las redes neuronales es en precisión y en que requieren menor interacción de parte del usuario.

### Aplicación a la Reposición de Inventarios

El proceso de reposición de inventarios en la cadena de

supermercados en estudio tiene algunas restricciones importantes que se deben incluir en la modelación. El principal punto es que la reposición por parte de los proveedores se realiza para la mayoría de los productos, cada  $P$  días y la orden de compra debe emitirse con al menos  $L$  días de anticipación a la fecha del despacho. Debido lo anterior, el sistema de reposición a usar es del tipo revisión periódica de inventarios. Las restricciones del problema determinan el tiempo entre órdenes. Lo que queda por fijar es el inventario objetivo ( $T$ ) al cual se debe llegar en cada período. Este se calcula a través de la ecuación  $T = m' + Z \sigma$

**Nivel de Inventario e Inventario Objetivo (figura 6)**



Donde  $m'$  es la demanda media durante  $P + L$  días y  $Z_s$  es el stock de seguridad, el que depende del nivel de servicio deseado ( $Z$ ) y de  $s$ , desviación estándar de la demanda durante  $P+L$  días.

El beneficio del pronóstico de corto plazo es la estimación dinámica (que cambia en el tiempo) de la demanda. De esta forma, el pronóstico se usa para calibrar la demanda promedio durante el período entre órdenes ( $m'$ ). A continuación se grafica el nivel de inventario del producto 100595 y el inventario objetivo, usando el modelo de reposición propuesto.

Comparando la situación actual (promedio) con los resultados obtenidos con el modelo propuesto, se logran mejoras tanto en el nivel de servicio entregado a los clientes (medido por los quiebres de venta), como en los costos de capital inmovilizado por inventario (medido en días de alcance promedio). Los resultados se resumen en la tabla 3.

los híbridos para predecir con mayor precisión las series de tiempo [2]. Los primeros resultados son muy promisorios y se espera tenerlos pronto dentro de los sistemas de pronóstico en producción.

El uso de estas herramientas predictivas sin duda que mejora la gestión sobre el inventario que realizan las empresas. Sin embargo, estos sistemas pueden potenciar aún más sus beneficios, si existe colaboración entre empresas de retail y proveedores. Si la información del Punto de Venta que tienen los retail es compartida y distribuida hacia la cadena, esto permitirá generar importantes ahorros en costos de inventario y evitar los nocivos problemas del mencionado efecto látigo. En Chile, sin embargo, son muy pocos los esfuerzos en este ámbito, debido a que prima un espíritu de competencia y celo respecto de la información que maneja cada empresa de retail.

### Comparación del Desempeño entre el Sistema Actual y el Propuesto para la Reposición

| Indicador Control de Gestión de Inventarios     | Sistema Actual | Sistema Propuesto |
|---|----------------|-------------------|
| Días de Alcance (Inventario/promedio de ventas) | 30 días        | 5 días            |
| Quiebres de Venta (% de días sin productos)     | 6%             | 0.9%              |

### Nuevas Tendencias

A continuación se mencionan algunas tendencias que tendrán impactos para la predicción de demanda de los consumidores, y por ende a la cadena de suministro.

El área de sistemas inteligentes híbridos es una con muchos desarrollos tanto teóricos como prácticos donde se trata de combinar varios modelos para llegar a un mejor sistema. Los autores de este artículo desarrollaron varios mode-

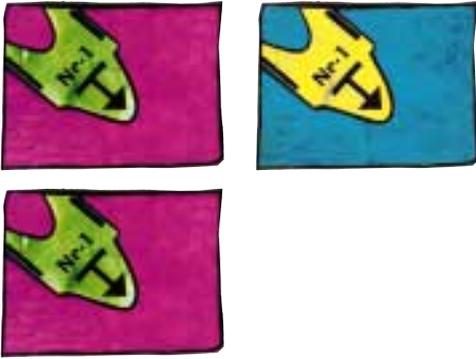
La tecnología también ha realizado sus aportes para mejorar los flujos de información entre los distintos agentes de la cadena de suministro. De esta forma surgen tecnologías como EDI (Electronic Data Interchange) y ahora, también, las transacciones seguras sobre Internet, que han permitido aumentar la seguridad y eficiencia en las emisiones de órdenes de compra entre retails y proveedores.

Un nuevo enfoque en lo referente a tecnología es el RFID (Radio Frequency Identification). Esta tecnología ofrece un potencial enorme a la cadena de suministro al poder identificar únicamente y a cierta distancia, cada uno de los ítems involucrados. Empresas como SAP por ejemplo, ya están desarrollando agentes inteligentes que usan los datos provenientes de RFID para tomar decisiones como reposición automática si el inventario llega a cierto mínimo.

Implementar un sistema de pronóstico puede ser visto como algo complejo y costoso. Compra de software, hardware, capacitación para el manejo de la herramienta, comunicación con los sistemas transaccionales de la empresa, entre otras, son las dificultades que aparecen a la hora de embarcarse en esta idea.

En Norteamérica, durante los últimos cinco años, se ha venido experimentando un fuerte aumento en las soluciones ASP en sistemas de Inteligencia de Negocios. Este tipo de soluciones consiste en que el cliente "arrienda" el servi-





cio (en este caso, el sistema de pronóstico) a un proveedor de desarrollos. Esto permite que el cliente no realice grandes inversiones en la implementación del desarrollo y que pueda ocupar o dejar de ocupar el sistema cuando el cliente lo estime conveniente. No hay duda que este enfoque trae muchas ventajas a los clientes y es así como en Chile ya hay empresas que comienzan a proveer este tipo de soluciones en sistemas de Inteligencia de Negocios.

### Un Día Cualquiera...

Un supermercado que aplique sistemas avanzados de pronóstico de demanda -como por ejemplo aquellos descritos en este artículo- podrá satisfacer la demanda de sus clientes y ofrecer sus productos a bajos precios, y Usted encontrará siempre su helado de Pie de Limón en el lugar de siempre, fresco y barato. •

### Referencias

[1] Aburto, L., Weber, R. Demand Forecast in a Supermarket Using a Hybrid Intelligent System. HIS 2003 pp. 1076-1083. Australia. 2003.

[2] Aburto, L., Weber, R. Sistema de Pronóstico de Ventas Utilizando Redes Neuronales y su Aplicación en la Cadena de Suministro de un Supermercado. XI CLAIO. Concepción, Chile. 2002

[3] K. Bansal, S. Vadhavkar y A. Gupta. Neural Networks Based Forecasting Techniques for Inventory Control Applications. Data Mining and Knowledge Discovery 2, pp. 97-102. 1998.

[4] G. E. P. Box y G. M. Jenkins. Time Series Analysis: Forecasting and Control. Holden-Day, San Francisco. 1976.

[5] C. Brax. Recurrent Neural Networks for Time Series Prediction. Department of Computer Science, University of Skövde. Skövde, Suecia. 2000.

[6] G. Dorffner. Neural Networks for Time Series Processing. Neural Network World. 6 (4) pp. 447-468. 1996.

[7] J. Faraway y C. Chatfield. Time series forecasting with neural networks: a comparative study using the airline data. Applied Statistics 47(2), pp. 231-250. 1998.

[8] J. Han y M. Kamber. Data Mining: Concepts and Techniques. Morgan Kaufmann Publishers. San Francisco. 2001.

[9] T. Hill, M. O'Connor y W. Remus. Neural Networks for Time Series Forecasts. Management Science, 42 (7), pp. 1082-1092. 1996.

[10] C. Kuoy A. Reitsch. Neural networks vs. conventional methods of forecasting. The Journal of Business Forecasting Methods and Systems, 14(4), pp. 17-22. 1995.

[11] D. Lambert, J. Stock, L. Elbron. Fundamentals of Logistics Management. Irwin McGraw-Hill. 1998.

[12] C. C. Reyes-Aldasoro, A. Ganguly, G. Lemus y A. Gupta. A Hybrid Model Based on Dynamic Programming, Neural Networks and Surrogate Value for Inventory Optimisation Applications. Journal of Operational Research Society, Vol. 50, No. 1, pp. 85-94. 1999.

[13] R. G. Schroeder. Administración de Operaciones, University of Minnesota. Mc Graw Hill. 1992.

[14] K. Smith y J. Gupta. Neural networks in business: techniques and applications for the operations researcher. Computers and Operations Research, volume 27, number 11-12, pp. 1023-1044. 2000.

[15] F. M. Thiesing y O. Vornberber. Sales Forecasting using Neural Networks. Proceedings International Conference in Neural Networks 97, Houston. Vol. 4 pp. 2125-2128. 1997.

