Aplicación de las redes neuronales a la previsión del stock en empresas "Pool"

Oscar Sapena, Vicente Botti, Estefanía Argente Departamento Sistemas Informáticos y Computación Universidad Politécnica Valencia, Camino de Vera s/n 46071 Valencia, España.

e-mail: {osapena, vbotti, eargente}@dsic.upv.es

Resumen: En la actualidad, para muchas empresas resulta esencial la realización de previsiones ajustadas de sus stocks de materiales con objeto de reducirlos al mínimo y así la inversión realizada en los mismos sea la menor posible. En el caso concreto de empresas "Pool", esta necesidad se hace aún más acusada, ya que han de mantener la calidad del servicio a la vez que intentan minimizar la inversión en inmovilizado. Para realizar una previsión ajustada se han empleado técnicas de inteligencia artificial, en particular, las redes neuronales artificiales.¹

Claves: previsión, stock, redes neuronales.

1 Introducción

Hoy en día muchas empresas requieren el uso de previsiones para ajustar el stock de material que guardan en sus almacenes. Las empresas "Pool" se encargan de alquilar cierto tipo de material a un conjunto de clientes. Estas empresas se componen de varias plataformas distribuidoras (o almacenes) situadas en diferentes localidades. Cada plataforma abastece a un conjunto conocido de clientes locales. Existen otros clientes que, por su zona de actuación, pueden conseguir los materiales en distintas plataformas.

El recorrido que siguen los materiales alquilados comienza en una plataforma distribuidora de la empresa; los clientes cargan los artículos en sus camiones cuando los necesitan. Es importante que los clientes encuentren dichos productos en el almacén ya

¹ Este trabajo está enmarcado dentro del proyecto CICYT-FEDER nº 0887 "Sistema de Gestión y Optimización de Stock para Empresas POOL" (1999 – 2001)

que la disponibilidad inmediata de la mercancía es un valor añadido para la calidad del servicio que proporcionan. Tras su uso, los clientes devuelven los materiales a la planta distribuidora donde se preparan para su reutilización.

La empresa con la que hemos colaborado trabaja con periodos semanales. Al principio de cada semana conoce el stock de cada artículo que tiene en cada almacén y las entradas de cada tipo de artículo que se producirán durante la semana en curso. Lo que le es desconocido es la cantidad de cada artículo que los clientes se llevarán de cada plataforma. Este dato le permitiría a la empresa ajustar la cantidad de stock que debería mantener en cada almacén. El stock sobrante (excedentes) previsto se puede distribuir entre los clientes no locales, indicándoles que carguen sus camiones en determinadas plataformas excedentarias. En determinadas circunstancias también es posible realizar traspasos de material entre plataformas para equilibrar el stock entre las mismas.

En este artículo se intenta resolver el problema de la previsión de stock mediante el empleo de redes neuronales. Las redes neuronales artificiales se están aplicando actualmente a un gran abanico de áreas científicas y tecnológicas: clasificación de datos y reconocimiento de patrones, proceso de imágenes, robótica, medicina, administraciones públicas, aplicaciones militares y financieras, etc. En el ámbito empresarial también se ha aplicado esta herramienta a múltiples problemas: predicción de crisis empresariales, selección de órdenes de compra, análisis de mercados, etc.

La estructura de este artículo es la siguiente: en el próximo punto describimos el concepto de empresa "Pool". En el tercer punto definimos los objetivos que pretendemos alcanzar. El cuarto apartado describe a grandes rasgos los tipos de redes neuronales que pueden servir para este propósito. Se prosigue con la descripción de la solución desarrollada. Se exponen, tras este apartado, los resultados que se han conseguido. Por último se incluyen las conclusiones obtenidas y la bibliografía.

2 Descripción del problema

Durante muchos años los costes del transporte de mercancías han sido objeto de análisis y estudios por todo tipo de empresas, debido a la incidencia que estos costes tienen sobre el precio final de los productos. Parte del proceso de mejora realizado en el tratamiento de stocks ha venido derivado por lo que se ha conceptuado como "Unidades de Transporte" (UT). Con el estudio de las UTs se han conseguido grandes progresos en la estandarización, así como economías en la manipulación y transportes de mercancías. Ley 11/1997 Europea sobre envases y residuos de envases, define las alternativas o usos que del envase se realizará una vez utilizado:

• Reutilizable: el envase está diseñado para realizar un número mínimo de circuitos, rotaciones o usos a lo largo de su ciclo de vida.

- Reciclado: la transformación de residuos de envases, sin recuperación de energía.
- *Valorización*: aprovecha los recursos contenidos en los residuos de envases.
- Energéticamente recuperable: uso de residuos de envases para generar energía.
- *Eliminación*: todo procedimiento dirigido, bien al almacenamiento o vertido controlado de los residuos de envases o bien a su destrucción, total o parcial.

Del análisis de los anteriores conceptos, de sus ventajas e inconvenientes, surge el nacimiento de las empresas "Pool" de envases de plástico.

2.1 Empresa "Pool"

Las empresas "Pool" se caracterizan por la prestación de un servicio de alquiler de envases (ERTs), o unidades de transportes (UTs) a las distintas empresas productivas o envasadoras de productos de alimentación, bajo los siguientes condicionantes:

- La empresa "Pool" es la propietaria de todos los ERTs, cediéndolos para su utilización, y cobrando un alquiler por el uso y una fianza como garantía de su devolución.
- Coordina los stocks en los centros operacionales (plataformas reguladoras, de servicio, almacenes de productores/envasadores y distribuidores). La empresa "Pool" se responsabiliza del mantenimiento del parque.
- Los almacenes de esta empresa deben de estar correctamente comunicados, gestionados, pues es esencial para dar un alto nivel de respuesta a la demanda de ERTs.
- Sistema operativo o flujo físico de los ERTs (*Figura 1*).

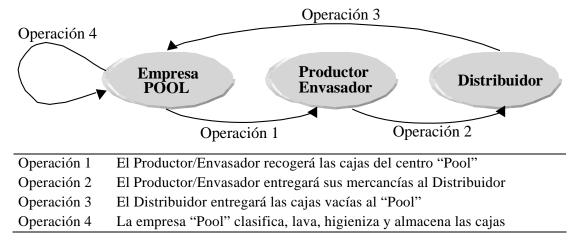


Figura 1. Flujo físico de los envases reutilizables de transporte.

3 Objetivos

El objetivo que perseguimos es el de realizar una previsión lo más exacta posible de la cantidad de artículos que se llevará cada cliente en cada almacén; la empresa, de este

modo, podrá disminuir el stock en las plataformas y aumentar sus beneficios. La previsión debe ser adaptativa, de forma que vaya ajustándose a las nuevas necesidades de cada cliente.

Para resolver este problema hemos decidido aplicar técnicas de inteligencia artificial para resolverlo. En concreto, la técnica elegida ha sido las redes neuronales, que se explicarán con más detalle en el siguiente apartado. Desde el trabajo pionero de White (1988), la aplicación de las redes neuronales a las finanzas ha sufrido un crecimiento exponencial tanto en investigaciones como en publicaciones [Lu'99]. A partir de entonces estos modelos se han ido aplicando a la predicción económica con gran éxito. Así mismo, las redes neuronales se adaptan bien a los cambios el sistema que modelan mediante el reentrenamiento de las mismas. Su uso es bastante sencillo en comparación con otras técnicas como los análisis estadísticos tradicionales y permiten la generación de modelos más complejos que simples combinaciones lineales.

Existen una gran cantidad de variables exógenas que pueden influir en el sistema (factores medioambientales, epidemias, fluctuaciones de la demanda, etc.) y que dependen de las actividades propias de cada cliente. La imposibilidad de un análisis independiente de cada cliente nos obliga a realizar previsiones en función de las pocas variables conocidas, intentando obtener, a pesar de todo, unos resultados suficientemente aproximados para mejorar la gestión de stocks de la compañía.

4 Redes neuronales artificiales

Las redes neuronales facilitan mecanismos generales para construir modelos de sistemas a partir de datos de los mismos. Consisten en un conjunto de unidades primitivas (neuronas) que trabajan en paralelo y que están conectadas a través de enlaces (arcos). En estos modelos la información se distribuye a través de la red y se almacena en la estructura de la topología y en los pesos de los arcos. Existen tres tipos de neuronas: las neuronas de entrada se activan de acuerdo a las variables del problema en cuestión; las neuronas de salida señalan la respuesta de la red al patrón de entrada; el resto se denominan neuronas ocultas puesto que no son visibles desde el exterior. Las neuronas, según su función, se suelen agrupar por capas.

Los parámetros fundamentales de una red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexión entre neuronas. Según estos parámetros existen diferentes modelos de redes neuronales, como los mapas autoorganizativos [Kohonen'97], las redes de *Hopfield* [Corchado'00], etc., aunque los más interesantes para aplicaciones de previsión son las redes multicapa con propagación hacia delante [Freeman'93] y las redes recurrentes [Hammer'00].

- Redes multicapa con propagación hacia delante: además de una capa de entrada y otra de salida, esta tipología incluye una o más capas intermedias. La capa de entrada actúa como una capa sensorial que capta las señales de entrada externa y las propaga hacia la primera capa intermedia, y así sucesivamente, hasta llegar a la capa de salida que proporciona la respuesta ante el estímulo externo. La propagación de las señales a través de la red es siempre hacia delante o acíclica [Corchado'00].
- Redes recurrentes: se diferencian de las redes con propagación hacia delante en el hecho de presentar, al menos, un ciclo dentro de la red. Por lo tanto, las señales ahora no sólo se propagan desde la entrada hacia la salida, sino que existe una realimentación, de forma que la salida de una neurona en un determinado camino es, a su vez, entrada para otra neurona anterior del mismo camino.

Estas dos tipologías de red suelen emplearse con el perceptrón como modelo de neurona y, además de una capa de entrada y otra de salida, suelen tener una o más capas ocultas. La función de activación suele ser de tipo sigmoide excepto para las neuronas de la capa de salida que suele ser lineal [Stuttgart'95].

5 Descripción de la aplicación

El diseño de una red neuronal presenta similitudes con los procedimientos empleados en la programación clásica. Podríamos establecer las siguientes etapas:

5.1 Definición del problema a resolver

La única información que se dispone para la previsión del stock es un histórico con los movimientos realizados por los clientes de las plataformas durante dos años. No se ha realizado un estudio profundo de las posibles variables externas que podrían influir en el modelo ya que dependerían de cada cliente y de su actividad, lo que supondría un enorme esfuerzo y la imposibilidad de incluir nuevos clientes a la aplicación sin modificarla. Además, variables que podrían participar en el modelo como las temporadas de los productos y las condiciones atmosféricas son, a su vez, imprevisibles por lo que no podríamos emplearlas como entradas de la red.

5.2 Codificación de la información. Entradas y salidas de la red

La fecha, descompuesta en día, semana y año, se ha incluido como entrada puesto que es relevante en el comportamiento: un cliente no recoge el mismo número de cajas de un año para otro (va evolucionando); además, no trabaja del mismo modo durante todo el año (hay clientes que sólo trabajan durante determinadas temporadas, dependiendo del producto con el que comercien); de la misma forma, por su forma de operar, cada

cliente tiene sus preferencias sobre el día de la semana en el que quiere recoger los artículos. La red se probó también sin incluir la fecha como entrada, incluyendo el número del mes, y realizando muchas otras combinaciones, pero el resultado obtenido fue peor. Por otro lado, se incluye una ventana temporal donde se reflejan las cantidades que se llevó el cliente los seis días anteriores a dicha fecha. De la misma forma, se ha probado también con diferentes tamaños para dicha ventana temporal, sin conseguir reducir el error cometido.

Parámetro	Nº neuronas	Codificación normalizada	
Año	1	(Año – 1997) / 10	
Semana del año	27	Codificación binaria de Jonson	
Día de la semana	6	Una neurona por día de la semana, excepto el domingo	
Ventana	6	Valor de la salida en los seis días anteriores	

Tabla I. Capa de entrada de la red neuronal.

Debido a la función de activación de las neuronas, es conveniente codificar la entrada entre 0 y 1. Por ello, la variable "año" recibe un valor 0 en 1997, y va incrementándose en una décima sucesivamente. Para la semana del año se ha empleado la codificación de *Johnson* para reducir el número de neuronas de entrada y porque posee ciertas características interesantes que la red puede aprovechar: dos semanas consecutivas se diferencian al codificarse en un solo bit, al igual que la última semana del año y la primera del año siguiente. Hemos incluido también una neurona asociada a cada día de la semana, exceptuando el domingo que no es laborable. Por último, la codificación de la ventana temporal se ha realizado dividiendo la cantidad de artículos que alquiló cada día entre un máximo. Este máximo puede variar si el cliente va aumentando la demanda de material con el tiempo; sin embargo, se puede solucionar este problema reentrenando la red neuronal con este nuevo máximo. Se ha probado realizando una normalización estadística pero los datos resultantes salían a menudo del intervalo [0..1] y la salida de la red tenía un alto error.

En la capa de salida se incluye únicamente una neurona que representa la cantidad de material que el cliente se llevó dicho día, dato que debe multiplicarse por el valor máximo arriba comentado para que la cantidad vuelva a estar en las unidades correspondientes.

5.3 Modelo de la red

No existe una regla para seleccionar una topología determinada de red dado un problema. Por lo tanto se probaron múltiples estructuras de red, tanto recurrentes como sin realimentación, con diferentes capas ocultas y distinto número de neuronas por capa.

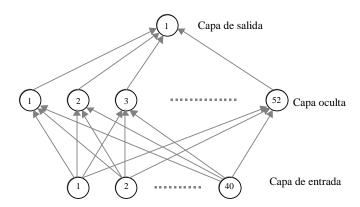


Figura 2. Tipología de red seleccionada.

Puesto que las redes recurrentes poseen ya realimentación, no es necesario incluir en los datos de entrada la ventana temporal. Los resultados obtenidos con este tipo de red resultaron inferiores a los perceptrones multicapa. La configuración que se mostró más idónea, respecto al error cometido en el conjunto de muestras de prueba, fue un perceptrón multicapa con una capa oculta de 52 neuronas. Las neuronas de cada capa estaban conectadas con todas las neuronas de la capa anterior (*Figura 2*).

5.4 Entrenamiento de la red neuronal

Las redes se han entrenado empleando el algoritmo "Back-Propagation" [Freeman'93], con un factor de aprendizaje de 0,01. Existen otros métodos de aprendizaje como el "Quick-Propagation" [Freeman'93], el algoritmo de "retropropagación del error con momentum" [Freeman'93], etc., que teóricamente convergen más deprisa; pero al ser un entrenamiento automático (sin supervisión por parte del usuario) se buscaba un comportamiento más estable antes que la velocidad de proceso.

La condición de parada del entrenamiento empleada ha sido un límite en el número de ciclos y una comprobación de que el error que comete la red sobre una serie de muestras de validación no aumenta (el 10% del total de muestras, escogidas aleatoriamente); con esto último intentamos evitar el sobreentrenamiento de la red [Prechelt'94]. En la aplicación implementada, para cada cliente, tipo de artículo y plataforma se ha entrenado una red neuronal (partiendo siempre del modelo que muestra la *Figura 2*).

6 Resultados

Los resultados conseguidos han sido bastante satisfactorios como se puede observar en las siguientes gráficas. Cada gráfica corresponde a un cliente distinto y muestra la simi-

litud de las previsiones respecto a los datos reales. Los datos empleados para generar las gráficas son muestras que no se han empleado durante el proceso de entrenamiento.

Se puede comprobar que la previsión de la primera semana es muy ajustada. El resultado va empeorando conforme se alarga el plazo de la previsión; esto se debe a que para los datos de entrada se emplean los datos de las previsiones anteriores y por lo tanto el error se va propagando. Sin embargo esto no supone un problema importante ya que la empresa en cuestión trabaja con periodos semanales.

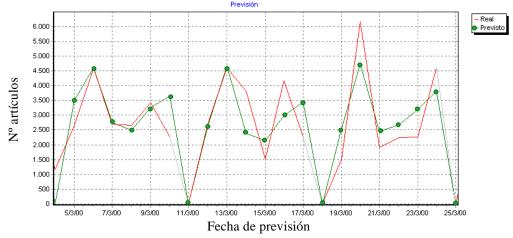


Figura 3. Previsión de alquiler de productos para el cliente 1.

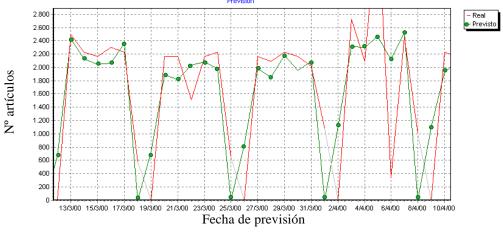


Figura 4. Previsión de alquiler de productos para el cliente 2.

Las bajadas en las gráficas que se producen a intervalos regulares se deben a los fines de semana, ya que los clientes no suelen recoger cajas los sábados o domingos (un día u otro). Para ilustrar de forma cuantitativa estos resultados se adjunta la siguiente tabla (*Tabla II*) donde se ha realizado la previsión para la siguiente semana de varios clientes; estos datos han sido facilitados directamente por la empresa, la cual emplea esta herramienta para sus previsiones. En la primera columna se indican los artículos

alquilados durante dicha semana mientras que en la segunda aparece la cantidad prevista de los mismos. El error cometido que se muestra en la última columna se ha calculado de la siguiente manera:

$$\%Error = \left| \frac{\text{ValorPrevisto} \times 100}{\text{ValorReal}} - 100 \right|$$
 (1)

El error cometido para cada cliente de una plataforma distribuidora oscila entre un 1 y un 10 %. Sin embargo, y como se puede observar en la última fila de la tabla donde se muestran los totales, la previsión de la cantidad total de artículos alquilados de un determinado tipo en una plataforma es muy buena en la mayoría de los casos (< 2%.) Esto se debe a la compensación entre los errores cometidos individualmente, pero el dato que le interesa a la empresa es el total de artículos que se recogerán en cada plataforma.

Valor real	Valor previsto	Error
20.196	21.145	4,69 %
4.176	4.228	1,25 %
6.480	6.871	6,03 %
7.380	6.902	6,47 %
12.168	11.706	3,79 %
4.608	4.580	0,6 %
2.412	2.645	9,66 %
3.456	3.575	3,44 %
4.032	3.990	1,04 %
64.908	65.642	1,13 %

Tabla II. Resultados obtenidos.

7 Conclusiones

Con estos resultados obtenidos se demuestra que las redes neuronales aproximan con suficiente exactitud el comportamiento de los clientes de la empresa "Pool", a pesar de que sólo se dispone de un pequeño histórico para su entrenamiento.

Las redes neuronales constituyen por lo tanto una gran herramienta de predicción, sobretodo cuando se trabaja con datos con ruido, no lineales, o cuando necesitan adaptarse rápidamente a nuevas situaciones. Además, su uso es muy sencillo a la hora de realizar la previsión. La opción de realizar análisis estadísticos supone un esfuerzo de diseño mayor y un estudio más exhaustivo para obtener unos resultados similares.

Por el contrario, es difícil justificar los resultados debido a que las redes neuronales adoptan un enfoque de "caja negra". Además, los periodos de entrenamiento pueden resultar muy largos en determinadas situaciones (no en nuestro caso): entrenar la red

para un sólo cliente, en una plataforma y para un artículo determinado suele tardar alrededor de 4 ó 5 minutos; esto supone varias horas de cómputo para todo el proceso.

El sistema está siendo utilizado en la actualidad para la previsión del stock en las siete plataformas de la empresa. Durante los once meses de utilización este sistema ha resultado muy satisfactorio, sin llegar a cometer un error en la previsión superior al 2%. Por último, este trabajo es una evidencia de la utilidad real de la IA. en la resolución de problemas empresariales. Esta técnica ha supuesto para la empresa un beneficio económico puesto que ha mantenido la calidad del servicio, sin un incremento en el inmovilizado y aumentando la cantidad de artículos alquilados.

8 Agradecimientos

Al grupo de investigación de Inteligencia Artificial del Departamento de Sistemas Informáticos y Computación y al personal de la empresa Logifruit S.L., que en estrecha colaboración me han ayudado a la consecución de este trabajo.

9 Referencias

- [Corchado'00] Corchado, J.M. (2000): Juan Manuel Corchado, Fernando Díaz, Lourdes Borrajo, Florentino Fernández. *Redes neuronales Artificiales. Un Enfoque Práctico*. Servicio de Publicaciones de la Universidad de Vigo.
- [Freeman'93] Freeman, J.A.; Skapura, D.M. (1993): *Redes Neuronales: Algoritmos, Aplicaciones y Técnicas De Programación*. Addison-Wesley.
- [Hammer'00] Hammer, B. (2000): Learning with recurrent neural networks. Springer.
- [Kohonen'97] Kohonen, T. (1997): Self-organizing maps. Springer.
- [Lu'99] Lu, Chun-Feng (1999): Would Evolutionary Computation Help for Designs of Artificial Neural Nets in Financial Applications?. Masterlink Securities Corporation.
- [Prechelt'94] Prechelt, L. (1994): *PROBEN1 A Set of Benchmarks and Benchmarking Rules for Neural Network Training Algorithms*. Technical Report 21/94. Fakultät für Informatik, Universität Karlsruhe.
- [Sttutgart'95] Sttutgart, (1995): SNNS Stuttgart Neural Network Simulator. User Manual, Version 4.1. University of Stuttgart.