

Previsión de precios y demanda en la gestión hotelera.

David de la Fuente¹, Raúl Pino¹, Jesús Lozano¹, Alberto Gómez¹

¹ Dpto. de Admón. de Empresas y Contabilidad, Área de Organización de Empresas. Escuela Politécnica Superior de Ingeniería de Gijón. Universidad de Oviedo. Campus de Viesques, s/n. 33204 Gijón (Asturias). david@uniovi.es, pino@epsig.uniovi.es, lozano@epsig.uniovi.es, agomez@epsig.uniovi.es

Resumen

Podría definirse el Yield Management como un método a través del cual es posible obtener la combinación de demanda más beneficiosa para una capacidad de oferta restringida, a través de un marco racional de análisis. En este trabajo, se realiza una de las tareas principales dentro del marco global del Yield Management, como es el cálculo de previsiones de la demanda, utilizando una metodología clásica como la Arima de Box-Jenkins, y otra más actual derivada de la Inteligencia Artificial como son las Redes Neuronales Artificiales. Con los resultados de las previsiones y las políticas generales de precios, es posible, a través del Yield Management hacer la asignación óptima de precios y ofertas con el objetivo final de la maximización de beneficios.

Palabras clave: Previsión, Yield Management, Redes Neuronales Artificiales.

1. Introducción

Son numerosas las definiciones de *Yield Management* (YM) que podemos encontrar. Kimes (1997) define Yield Management como “un método de apoyo que permite a la empresa vender el número de unidades adecuadas, al tipo de consumidor conveniente, en el momento preciso y al precio pertinente”. El problema proviene, por tanto, de determinar la cantidad a vender, el precio y el segmento de mercado adecuado.

En la práctica, el Yield Management pretende determinar los precios de acuerdo con la demanda prevista, de tal modo que los clientes sensibles al precio, que buscan comprar en momentos de baja demanda, puedan hacerlo a precios favorables y los clientes menos sensibles al precio, que desean comprar en los momentos de mayor demanda, puedan hacerlo también. Abbot (1999) señala que el Yield Management ofrece una medida de la aplicación de precios bastante ajustada, porque combina el porcentaje de ocupación, con el precio medio diario para hallar la producción. El objetivo es maximizar las tarifas cuando la demanda exceda a la oferta o maximizar la ocupación cuando la oferta exceda a la demanda.

Otra de las definiciones dadas por los expertos en Yield Management apunta que se trata de una técnica económica que utiliza datos históricos y niveles de reservas actuales para calcular precios y pronosticar la demanda futura, permitiendo así optimizar los ingresos generados por la venta de un producto o servicio.

Según Jones (2000), la implantación de Yield Management mejora las actuaciones empresariales desde tres puntos de vista:

- Mejora el conocimiento que tenemos de nuestro cliente: forma de actuación y percepción del valor.
- Mejora la forma de gestión de información, permitiendo incrementar la eficiencia a la hora de manipular datos y crear estimaciones de demanda, que nos permitan ajustar los precios.
- Prevé los efectos de los cambios en reservas.

Los métodos que utiliza el Yield Management son múltiples: económicos, estadísticos, matemáticos, de organización y marketing, y los objetivos que persigue también son variados:

- Optimizar ingresos.
- Incrementar la demanda.
- Analizar comportamientos de clientes.
- Servir como herramienta de ayuda en la toma de decisiones.

De lo indicado se desprende que el Yield Management no es un método que funcione sólo cuando la oferta excede a la demanda (en este caso funcionaría para controlar la disponibilidad de tarifas), sino que resulta de especial interés para aumentar la cuota de mercado, a través del establecimiento de tarifas, en las situaciones en las que esto sea factible.

A modo de resumen podríamos decir que el objetivo del Yield Management, es obtener la combinación de demanda más beneficiosa para una capacidad de oferta restringida, a través de un marco racional de análisis.

En este trabajo se calculan previsiones a corto plazo de la demanda hotelera a través de varias metodologías, como son la metodología clásica ARIMA de Box-Jenkins (Box and Jenkins, 1970), y la de Redes Neuronales Artificiales.

2. Previsión a corto plazo del número de reservas

En este punto se trata de pronosticar las reservas de un establecimiento hotelero. El horizonte de previsión será de 1 día, es decir, se calculan las reservas para el día siguiente, o bien a una semana vista.

Los datos con los que se cuenta proceden de 6 hoteles pertenecientes a la una cadena hotelera española, que designaremos por FM, FC, FMI, FG, FCL, FER. En cada caso disponemos de datos del número de reservas para cada día desde el 19/01/2004 hasta el 04/06/2006.

Para cada día disponemos de la siguiente información: FECHA, D-0 (Reservas para el día de cálculo), D-1 (Reservas para el día de cálculo que se tenían el día anterior), D-2 (Reservas para el día de cálculo que se tenían 2 días antes), D-3 (Reservas para el día de cálculo que se tenían 3 días antes), ..., D-7 (Reservas para el día de cálculo que se tenían 7 días antes), D-14 (Reservas para el día de cálculo que se tenían 14 días antes), D-21 (Reservas para el día de cálculo que se tenían 21 días antes), D-30 (Reservas para el día de cálculo que se tenían 30 días antes), D-60 (Reservas para el día de cálculo que se tenían 60 días antes), D-90 (Reservas para el día de cálculo que se tenían 90 días antes).

En la figura 1 se muestra la representación gráfica de la serie temporal D-0 correspondiente a uno de los hoteles (FM).

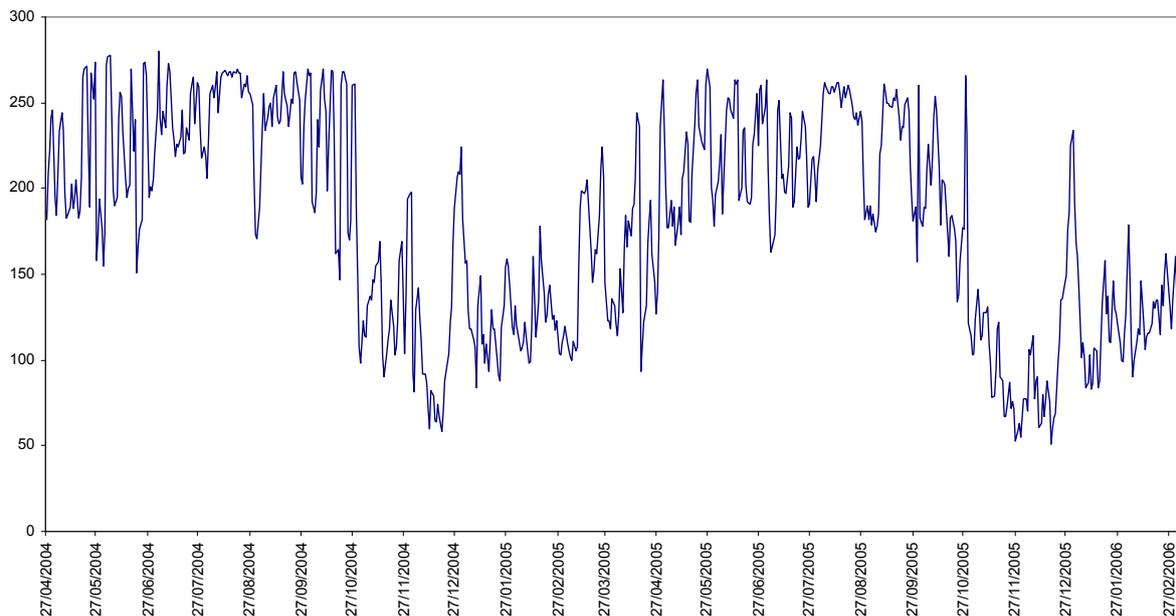


Figura 1. Datos reales de la serie temporal D-0 para el hotel FM.

Hemos añadido dos variables que suponemos muy influyentes en el número de reservas: el día de la semana para el que se pronostica, y el precio de la habitación. En este último caso, hemos hecho un estudio previo de los precios para simplificar los datos, puesto que, al proceder todos los datos de la misma cadena hotelera, se demostró que la política de fijación de precios en los 6 hoteles del estudio es prácticamente la misma, los precios varían según la temporada del año, subiendo o bajando de categoría de precio casi en los mismos días en todos los casos. Por tanto se fijaron unas categorías de precios que varían desde 1 (el precio más bajo) hasta 6 (el más alto).

En el caso del cálculo de previsiones con Redes Neuronales Artificiales, hemos optado por realizar dos cálculos distintos:

- En primer lugar se construyó una red que llamamos NN(14) que pronostica el número de reservas D-0 en función de 14 datos de entrada: D-1, D-2, ..., D-7, D-14, D-21, D-30, D-60, D-90, DIA_SEMANA y PRECIO. Se trata de hacer un cálculo de las previsiones “para el día siguiente”.
- En segundo lugar, se construyó otra red para el cálculo de previsiones “para la semana siguiente”. Esta red se llamará NN(8) y tendrá como datos de entrada: D-7, D-14, D-21, D-30, D-60, D-90, DIA_SEMANA y PRECIO.

Todas las tareas de construcción y entrenamiento de redes neuronales se han realizado utilizando el software “Easy-NN”. En la figura 2 se muestra una de las redes neuronales construidas, en este caso para la previsión a una semana. En la figura 3 aparecen clasificadas por orden de importancia las 8 entradas una vez concluido el entrenamiento. Se puede comprobar como la variable PRECIO es la segunda en importancia después del número de reservas la semana anterior, mientras que las otras 6 entradas no son tan importantes.

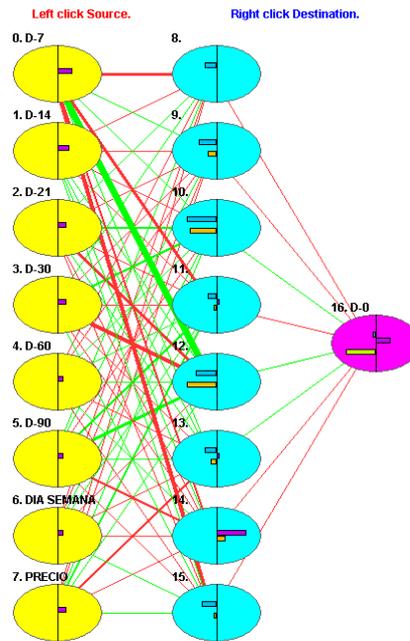


Figura 2. Estructura de una red neuronal NN(8).



Figura 3. Importancia de las entradas en una red neuronal NN(8).

Los resultados de las previsiones calculadas se muestran en la tabla 1. En ella se recoge el MAPE (Error medio porcentual en valor absoluto, introducido por Makridakis, 1993), para los 6 hoteles con las dos redes neuronales.

Tabla 1. Medidas del error en el cálculo de las previsiones con Redes Neuronales.

HOTEL	MAPE	
	NN(14)	NN(8)
FM	3.15%	7.95%
FC	2.64%	6.16%
FMI	4.38%	9.52%
FG	8.42%	17.27%
FCL	2.93%	10.29%
FER	6.04%	10.02%

Para el cálculo de previsiones mediante la metodología de Box-Jenkins, se ha evitado la utilización de complejos modelos multivariantes ya que las dimensiones del problema haría que el tratamiento de los datos fuera excesivamente complejo. Se ha optado entonces, por utilizar modelos univariantes en los que se obtiene la previsión de la demanda para el día

siguiente D-0 en función de 7 datos de entrada: D-1, D-2, ..., D-7. Repitiendo este cálculo para todos los días en cada uno de los 6 hoteles analizados, se han obtenido unos resultados que se muestran en la tabla 2, junto con los modelos de BJ utilizados en cada caso.

Tabla 2. Modelos de Box-Jenkins y MAPE de las previsiones.

HOTEL	Modelo BJ	BJ
FM	ARMA(2,1)	2.68%
FC	ARMA(2,1)	4.69%
FMI	ARMA(1,0)	5.33%
FG	ARMA(2,1)	5.20%
FCL	ARMA(2,1)	4.10%
FER	ARMA(4,3)	5.58%

En la tabla 3 se comparan los resultados mediante el MAPE las previsiones obtenidas mediante las dos metodologías. Se puede comprobar que ninguna de las dos proporciona mejores resultados para todos los casos sino que los errores son relativamente similares.

Tabla 3. Medidas del error en el cálculo de las previsiones con RN y Box-Jenkins.

HOTEL	MAPE	
	NN	BJ
FM	3.15%	2.68%
FC	2.64%	4.69%
FMI	4.38%	5.33%
FG	8.42%	5.20%
FCL	2.93%	4.10%
FER	6.04%	5.58%

3. Conclusiones

En este trabajo se ha llevado a cabo una de las partes fundamentales dentro del proceso de Yield Management para una empresa hotelera, como es el cálculo de previsiones de la demanda. Para realizar este cálculo, se han utilizado dos metodologías: la metodología clásica y sobradamente conocida de Box-Jenkins, y la aplicación de las Redes Neuronales Artificiales, una técnica derivada de la Inteligencia Artificial, pero que ha dado y está dando numerosas pruebas de su idoneidad para el cálculo de pronósticos sobre todo con modelos multivariantes como el que nos ocupa.

Los resultados muestran que ninguna de las dos metodologías es superior a la otra en todos los casos. Sin embargo, tenemos que destacar las posibilidades que ofrece la metodología de Redes Neuronales, con la que podemos calcular previsiones para el día siguiente (con la red NN14), o a una semana (red NN8), lo que aumenta la flexibilidad y el margen de maniobra para los gestores del sistema. Además, en las Redes Neuronales se pueden introducir variables adicionales en el proceso como el día de la semana para el que se hacen los pronósticos, y la categoría de precio. Incluir estas variables en los modelos de Box-Jenkins, lleva a tener que manejar complejos modelos multivariantes.

Referencias

Abbot, P. y Lewry, S. (1999). *Front Office: Procedures, social skills, yield and management*. Butterworth y Heinemann. Oxford.

Box, G.E. and Jenkins, G.M. (1970). *Time Series Analysis*. Holden-Day, San Francisco.

Jones, N. (2000). "Defining Yield Management and measuring its impact on hotel performance". In A. Ingold *et al* (eds.), *Yield Management: Strategies for the service industries*. London: Continuum.

Kimes, S. E. (1997). "The principles of Yield Management: an overview". In I. Yeoman and A. Ingold (eds.), *Cassell Yield Management: Strategies for the service Industries*. London.

Makridakis, S. (1993). "Accuracy Measures: Theoretical and practical concerns". *International Journal of Forecasting*, 9:527-29.