

OBTENCIÓN DE VARIABLES EXÓGENAS PARA MEJORAR LA PERFORMANCE DEL PRONÓSTICO A PARTIR DE ANÁLISIS MULTIVARIADO

Alejandra María Esteban¹

Claudia Noemí Zárate²

Verónica Aída Mortara³

María Betina Berardi⁴

RESUMEN: En este trabajo se analizó el comportamiento de un método de “*soft computing*” utilizado para pronosticar las ventas de productos de conserva de pescado de una empresa de la zona. Se pronosticaron las ventas correspondientes al último año, en forma mensual y se compararon los valores de las ventas reales con los obtenidos. Los pronósticos se realizaron utilizando un Sistema de Inferencia Neuro-Difuso Adaptativo -ANFIS- y se comprobó que en esta metodología la utilización de series exógenas adecuadas, mejora la performance de los mismos. El error de la predicción, se evaluó a través del *Error Porcentual Absoluto Medio* (MAPE). Las series exógenas se derivaron del Análisis de Componentes Principales que se realizó sobre el conjunto de datos originales. Los resultados obtenidos indican, que el Análisis de Componentes Principales resulta una herramienta poderosa, que permite contribuir en forma apropiada a la elaboración de series exógenas.

Palabras clave: Pronósticos. Industria conservera. Componentes principales. ANFIS.

1 INTRODUCCIÓN

El objetivo de la cadena de suministro es el de maximizar la rentabilidad, entendiéndose ésta como la diferencia entre los ingresos generados por el cliente y el costo total de la cadena de suministro. En las distintas etapas de la cadena de suministro se incurren en costos relacionados con la transmisión de información, producir los componentes, almacenarlos, transportarlos, transferir fondos, entre muchos más.

¹ Ingeniera Química, Profesor Asociado, Departamento de Ingeniería Industrial, Universidad Nacional de Mar del Plata, Buenos Aires, Argentina. E-mail: aesteban@fi.mdp.edu.ar.

² Mg. Ingeniera Mecánica, Profesor Asociado, Departamento de Ingeniería Industrial, Universidad Nacional de Mar del Plata, Buenos Aires, Argentina. E-mail: cnzarate@fi.mdp.edu.ar.

³ Esp. Ingeniera Química, Profesor, Departamento de Ingeniería Industrial, Universidad Nacional de Mar del Plata, Buenos Aires, Argentina. E-mail: vmortara@fi.mdp.edu.ar.

⁴ Ingeniera Química, Profesor, Departamento de Ingeniería Industrial, Universidad Nacional de Mar del Plata, Buenos Aires, Argentina. E-mail: bberardi@fi.mdp.edu.ar.

Si se consideran los dos enfoques que puede tener la cadena de suministro, es decir, enfoque tirón o enfoque empuje, en ambos casos los pronósticos son de suma utilidad. Todos los procesos de empuje de la cadena se realizan en respuesta de la demanda del cliente y el gerente debe planificar el nivel de actividad, ya sea en producción, en transporte o en cualquier actividad planeada. Para los procesos de tirón, el gerente debe planificar el nivel de capacidad disponible y el inventario. Para ambos casos el pronóstico es un dato indispensable para poder comenzar con dicha planificación.

La predicción de demanda tiene como objetivo mejorar el flujo de información en la cadena de suministro a la cual pertenecen las empresas y por lo tanto, preparar a la organización en medios técnicos, humanos y financieros para soportar las operaciones futuras de la empresa.

Existen diversas técnicas y métodos utilizados para predecir el comportamiento de la demanda basados en datos históricos, que van desde la simple recolección de información en el departamento de ventas y su posterior análisis y extrapolación, hasta métodos complejos basados en modelos econométricos y estadísticos (BALLOU, 2004).

Es de fundamental importancia considerar el error que inevitablemente viene asociado a toda predicción, a la hora de seleccionar el método que modele las series a pronosticar. Numerosos autores (CHU et al., 2003), han reconocido la importancia del mismo en el momento de la toma de decisiones. Un pronóstico con errores importantes puede llevar desde a un agotamiento de stock o excesivo costo de mantenimiento. También puede involucrar paradas de producción por falta de insumos, lo cual es prácticamente inadmisibles en la actualidad, considerando la tendencia de ajustar los costos para un mejoramiento continuo de la eficiencia.

En la actualidad, la disposición de pronósticos constituye una parte fundamental de la logística, por las implicaciones que su variación tiene en los principales procesos de la cadena de suministro (gestión de stocks, aprovisionamientos, transporte, fabricación, nivel de servicio, etc.), y por los beneficios que proporciona, su correcta estimación y control. Considerando a la cadena de suministro, la incertidumbre puede ser definida como eventos impredecibles que afectan a un comportamiento previsto de la misma. Bayraktar et al. (2008) analizan el efecto *Forrester* o de amplificación de la demanda a lo largo de toda la cadena de suministro y estudian sus causas, entre las que el error del pronóstico de la demanda tiene un lugar preferencial.

El objetivo de este trabajo es el de obtener pronósticos de ventas para 5 productos derivados de la industria conservera, cuya fábrica se encuentra en la región. Reconociendo la importancia de la precisión que se requiere en una predicción, se aplicarán distintos métodos y se evaluarán a través de los errores arrojados, más precisamente a través de la MAPE. El método que se utilizará para calcular los pronósticos será un Sistema de Inferencia Difusa *Neuro* Adaptativo, ANFIS, y se compararán con los resultados de la aplicación de la metodología ANFIS con aporte de variables exógenas derivadas del Análisis de Componentes Principales.

Este artículo se divide en 5 secciones. En la primera, se presentó la problemática a desarrollar. En la segunda sección se exponen los antecedentes del problema y cuáles son los avances logrados, brindando herramientas que permitirán discernir acerca de los resultados obtenidos. En la tercera sección se describen los métodos utilizados para la obtención del pronóstico y la aplicación del Análisis de Componentes Principales. En la cuarta sección, se exponen los resultados obtenidos y finalmente, en la quinta sección, las conclusiones a las que es posible arribar a partir del análisis de los resultados.

2 MARCO TEÓRICO

En esta sección se describe el Sistema de Inferencia Difusa, *Fuzzy Inference System* (FIS) y posteriormente el método *Neuro-Difuso Adaptativo*, *Adaptative Neuro-Fuzzy Inference System* (ANFIS), metodología empleada en este trabajo para la obtención de los pronósticos. En la segunda parte de esta sección se hace una introducción al Análisis Multivariado, y se explica la metodología de Análisis de Componentes Principales, fundamentándose su utilización en la obtención de series exógenas para mejorar el pronóstico.

2.1 Los sistemas de Inferencia Difusa

Diversas técnicas del área del “*soft-computing*” tales como Redes Neuronales Artificiales (RNA), Sistemas de Inferencia Difusa (FIS), y algoritmos evolutivos, han demostrado tener un amplio campo de aplicación en el área de los pronósticos.

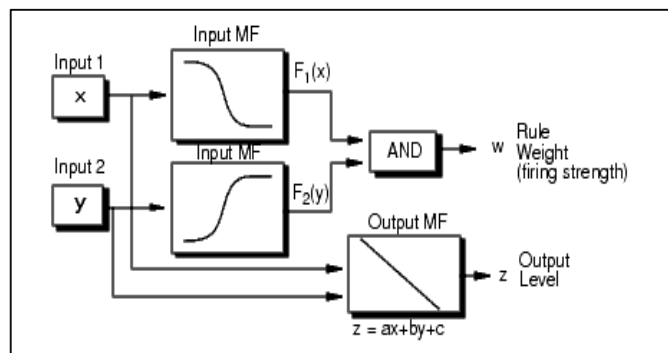
Las Redes Neuronales Artificiales (RNA), son técnicas inspiradas en el funcionamiento de sistemas biológicos y se han aplicado en numerosos trabajos demostrando ser una herramienta muy atractiva en el área de pronósticos. Aunque los resultados de muchos autores como Thomassey et al. (2005), Zhang (2003), entre otros, parecieran subordinados a

determinados contextos, su capacidad de modelar relaciones no lineales, su entrenamiento y facilidad, son potencialmente interesante para aplicaciones en el área de pronósticos.

Los Sistemas de Inferencia Difusa (FIS) también han sido aplicados a sistema de pronósticos, pudiéndose emplear los siguientes procesos:

- Un sistema de Inferencia Difusa, *Fuzzy Inference System* (FIS) es un proceso donde dada una entrada se obtiene una salida trabajando con lógica difusa, utilizando funciones de membresía o pertenencia a conjuntos difusos, operaciones lógicas y reglas si-entonces. En la Figura 1 se presenta un esquema que muestra una configuración FIS tipo Takagi-Sugeno.

Figura 1 – Configuración tipo Takagi-Sugeno



Fuente: MatLab®. Tutorial: *Fuzzy Logic Toolbox*

- Un Sistema de Inferencia Neuro-Difuso Adaptativo, *Adaptative Neuro-Fuzzy Inference System* (ANFIS), el cual opera dados datos de entrada-salida construyendo un sistema de inferencia difusa, cuyos parámetros de las funciones de membresía son ajustados usando, tanto algoritmos de retropropagación del error, solos o combinados con métodos de mínimos cuadrados. Este ajuste permite que los sistemas FIS aprendan de los datos que están modelando.

2.2 El análisis de Componentes Principales

Se denomina análisis multivariado o multivariante al conjunto de métodos estadísticos que se utilizan para analizar las observaciones multidimensionales.

Existe un número considerable de métodos multivariantes que se pueden clasificar en dos grandes grupos: métodos de regresión o de dependencia y métodos factoriales o de interdependencia.

Además, estos métodos también dependerán de los objetivos -predicción, representación, clasificación, entre otros- y de los tipos de datos -variables cuantitativas, variables cualitativas (categóricas), variables explicativas o variables explicadas.

Los métodos multivariantes de regresión o de dependencia se aplican en aquellos casos en los que una variable se destaca como dependiente principal. Se deberán emplear técnicas multivariantes analíticas o inferenciales, considerando a la variable dependiente como explicada por las demás variables independientes o explicativas.

En este caso, los métodos elegidos podrán ser:

- Regresión Lineal, para variables cuantitativas;
- Regresión Logística, variables cualitativas dicotómicas;
- Análisis Discriminante cuando sea necesario clasificar en categorías;
- Análisis de Varianza, en presencia de variables dependientes cuantitativas explicadas por cualitativas;
- Modelos Log lineales para tablas de contingencias de dimensión elevada;
- Modelos de Segmentación cuando la variable dependiente puede ser cuantitativa o cualitativa explicada por cualitativas.

Los métodos multivariantes factoriales o de interdependencia, son aquellos donde todas las variables tienen una importancia equivalente. Dependiendo del tipo de variable existen distintas técnicas:

- Para datos cualitativos son empleados el Análisis de Correspondencia y el Escalamiento Óptimo;
- Si la variable es cualitativa ordinal se acude al Escalamiento Multidimensional; y
- Para variables cuantitativas se utiliza Análisis de Componentes Principales y el Análisis Factorial.

Para interpretar un grupo de datos, compuesto por diversas muestras de distintas variables cuantitativas con una importancia similar, se utiliza Análisis de Componentes Principales.

La finalidad del Análisis de Componentes Principales, es obtener una representación sintética del conjunto de individuos con un grupo menor de variables, que se establecen como combinaciones lineales independientes entre sí de las variables originales (KENKEL, 2002).

El Análisis de Componentes Principales consiste en sintetizar la información de n individuos, dada por un conjunto de k variables X_1, X_2, \dots, X_K cuantitativas. Para ello, se calculan nuevas variables denominadas Componentes Principales, CP, funciones lineales de las variables X_k , que tienen la propiedad fundamental de ser incorrelacionadas entre sí y cuya variabilidad total es igual a la del conjunto original. Estas variables CP se ordenan por varianzas decrecientes, acumulándolas, hasta tener un porcentaje alto de la varianza total.

El Análisis de Componentes Principales tiene dos objetivos primarios (QUINN; KEOUGH, 2002):

- Reducir el número de variables a un número menor de variables derivadas que resuman la información adecuadamente y puedan ser utilizadas en análisis posteriores;
- Hallar patrones en los datos que no pueden ser encontrados cuando las variables se analizan separadamente.

Algunos autores como (AL SHAMI; LOFTI; DOSTÁL, 2014) argumentan la importancia de utilizar diferentes metodologías para descubrir la información oculta y externa de una serie, con la finalidad de mejorar el conocimiento de la misma, como una herramienta válida para corregir los pronósticos obtenidos.

En este trabajo se aplica la técnica de Análisis de Componentes Principales con la finalidad de encontrar patrones subyacentes que puedan ser usados para mejorar el pronóstico de la demanda. De esta forma se elabora un conjunto de datos que incorporan información adicional sobre posibles relaciones de causalidad entre dos o más series de tiempo, con vistas a lograr una mejora en la *performance* pronosticadora de los mismos.

3 DESARROLLO

En esta sección se presentan las series de datos que se utilizarán en el análisis, el método de obtención de pronóstico y la forma que se aplica para evaluar su precisión. Posteriormente se emplea el Análisis de Componentes Principales a dichos datos, se realiza la correspondiente interpretación para finalmente aplicar las mismas en la obtención del pronóstico.

3.1 Metodología utilizada

Para el desarrollo de este trabajo se partió de los datos reales de ventas mensuales durante 10 años de 5 productos: Atún en Aceite (AA), Atún al Natural (AN), Caballa en Aceite (CA), Caballa al Natural (CN) y Sardina en Aceite (SA) de una empresa conservera de Mar del Plata.

Se trabajó en forma similar a la metodología utilizada en publicaciones anteriores (CORRES et al., 2011, 2012), a partir de los datos de los primeros 9 años, se realizaron los pronósticos de ventas de los productos para el último año y posteriormente se compararon los resultados con las ventas reales correspondientes a ese décimo año.

El método aplicado para la obtención de pronóstico fue ANFIS, utilizando *subtractive clustering* como técnica de partición para generar el FIS y un posterior entrenamiento híbrido, que mezcla mínimos cuadrados con el algoritmo de retropropagación (*backpropagation*).

El software utilizado fue MATLAB®, *Toolbox* GENFIS2 y ANFIS. Los parámetros utilizados por el modelo fueron los que presentan las *Toolbox* por defecto, a excepción del radio de influencia (radii), cuyo valor se fue ajustando a través de la optimización del error de entrenamiento.

El Análisis de Componentes Principales (ACP) se realizó utilizando el software *PC-ORD® versión 6 for Windows*.

A partir de la Variación Explicada y del valor de los autovectores arrojado por ACP se obtuvieron las series exógenas que aumentaron la información proporcionada al ANFIS.

Los resultados de la aplicación de ANFIS y ANFIS con Variables Exógenas, se identificaron como F_i y F_i (Exo), siendo “i” AA, AN, CA, CN y SA, evaluándose los resultados a través de la medición del error. El error porcentual absoluto MAPE se utiliza como indicador de cuán grandes son los errores de pronóstico en comparación con los valores reales de la serie (Ecuación 1):

$$MAPE = \frac{1}{n} * \sum_{t=1}^{t=n} \frac{|A_t - F_t|}{A_t} \quad (1)$$

La MAPE normaliza los cálculos de error, y permite comparar los errores en el pronóstico para distintas series de tiempo.

3.2 Análisis de Componentes Principales

En el caso de estudio se utilizaron como variables, a las ventas reales de los 5 productos analizados durante los 12 meses del año. Del análisis surgen los meses de mayores y menores ventas y los productos más demandados según la época del año.

La Tabla 1 presenta la variación explicada de los 5 primeros ejes. Se observa que los dos primeros autovalores acumulan el 97.19 % de la variación total. Esto significa que estas dos primeras componentes sintetizan el 97% de la varianza y en consecuencia serán retenidas dado que el aporte de las restantes es despreciable.

Tabla 1 – Autovalores: variación explicada de los 5 primeros ejes VARIANCE EXTRACTED, FIRST 5 AXES

AXIS	Eigenvalue	Broken-stick		
		% of Variance	Cum. % of Var.	Eigenvalue
1	50748372.000	89.800	89.800	25807420.000
2	4177277.250	7.392	97.192	14504899.000
3	1274277.375	2.255	99.447	8853640.000
4	291833.594	0.516	99.963	5086133.500
5	20838.010	0.037	100.000	2260503.750

Fuente: *PC-ORD®. PCA*

En la Tabla 2 se presenta el valor de los autovectores. En las Ecuaciones 2 y 3 se expresan las componentes principales como una combinación lineal de las variables originales, donde los autovectores indican el peso correspondiente de cada una de las variables:

Tabla 2 – Autovectores

Variable	Eigenvector				
	1	2	3	4	5
AA MEN	-0.2204	0.0525	-0.0716	-0.9226	0.3038
AN MEN	-0.1366	-0.0865	-0.0823	-0.2767	-0.9437
CA MEN	-0.7421	0.4806	0.4372	0.1632	-0.0226
CN MEN	-0.3299	-0.8599	0.3791	0.0284	0.0852
SA MEN	-0.5228	-0.1392	-0.8082	0.2116	0.0968

Fuente: *PC-ORD®. PCA*

$$CP1 = -0,22 * AA - 0.1366 * AN - 0.7421 * CA - 0.3299 * CN - 0.5228 * SA \quad (2)$$

$$CP2 = 0,0525 * AA - 0.0865 * AN + 0.4806 * CA - 0.8599 * CN - 0.1392 * SA \quad (3)$$

Las componentes CP1 y CP2 definen un espacio de dos dimensiones, en el que se ubican los 12 meses del año, tal como se observa en el mapa representado en Figura 2, donde las CP1 y CP2 se grafican en los ejes 1 y 2 respectivamente.

3.2.1 Interpretación del Análisis de Componentes Principales

En el caso CP1, es importante observar que los valores correspondientes al autovector son de igual signo para todas las variables. Entonces, se puede asociar la CP1 con el volumen de ventas mensual relacionado con el período de tiempo. En el mapa de la Figura 2 se pueden observar los patrones de comportamiento, que estarían indicando que:

Figura 2 – Representación gráfica de CP1 y CP2



Fuente: PC-ORD®. PCA

- Los meses de junio, julio y agosto forman un grupo de menores valores de ventas, y
- El mes de marzo se caracteriza por ser el de mayores ventas para todos los productos.

La CP2 se puede asociar con la venta estacional de las caballas y en menor proporción de las sardinas. En abril, muestra un importante aumento la venta de CA (correlación positiva), en contraste con la ventas de CN y SA. En cambio, en noviembre se produce un significativo aumento de venta de CN y SA (correlación negativa) en contraposición a CA. No obstante, cabe señalar la importancia relativa de la variación de CA y CN respecto de SA.

3.3 Aplicación de las Componentes Principales a la obtención de pronóstico

A partir de los resultados del ACP, se aplicaron a las series de ventas reales de cada uno de los productos, en carácter de variables exógenas, nuevas series, de acuerdo a lo indicado en la Tabla 3.

Tabla 3 – Series exógenas utilizadas en el cálculo del pronóstico

i	Serie exógena 1	Serie exógena 2	Serie exógena 3
AA	VR _{AA} CP1		
AN	VR _{AN} CP1		
CA	VR _{CA} CP1 CP2	VR _{CN} CP2	VR _{CN}
CN	VR _{CN} CP1 CP2	VR _{CA} CP2	VR _{CA}
SA	VR _{SA} CP2		

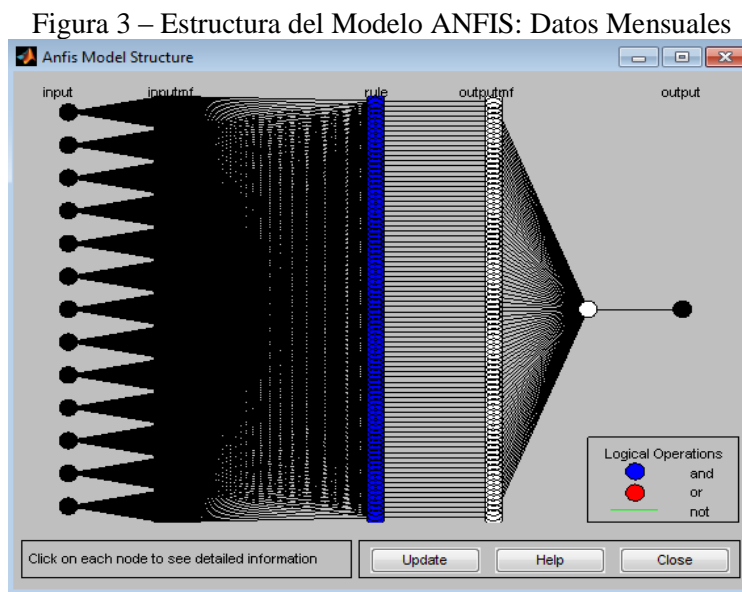
Fuente: Elaboración propia

La Tabla 3 muestra la conformación de las nuevas series exógenas, donde se indica como VR_i a la serie original correspondiente y CP1 o CP2 a las correcciones por el componente principal 1 y/o 2 respectivamente, que afectan a dicha serie (Ecuaciones 2 y 3). A modo de ejemplo, la serie VR_{AA}CP1, se refiere a la serie AA original afectada por la componente principal 1 que indica que las ventas en marzo aumentan un 22% y en junio, julio y agosto disminuyen dicho porcentaje.

4 RESULTADOS

En primer lugar se exponen los resultados del pronóstico sin intervención de series exógenas y posteriormente, los resultados con intervención de variables exógenas, como producto del Análisis de Componentes Principales. Se calcularon los pronósticos mensuales correspondientes al último año para cada uno de los 5 productos analizados.

La estructura del modelo ANFIS obtenida para los datos mensuales se muestra en Figura 3.

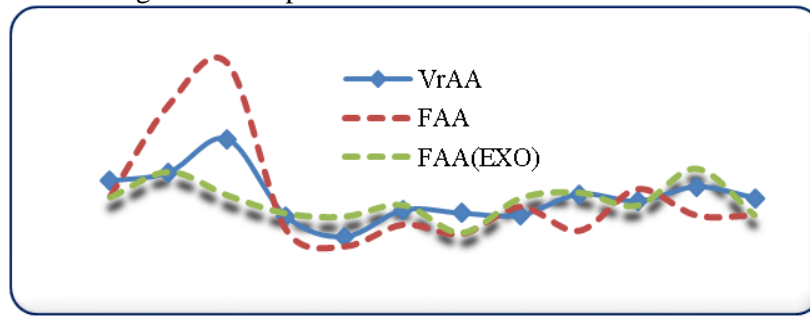


Fuente: MatLab®. ANFISEDIT

En la misma se observa el vector de 13 entradas al sistema, la conversión de las mismas a través de 84 funciones de membresía, sus reglas y la salida.

En las Figuras 4a y 4b se representan las ventas reales de AA y AN respectivamente, el pronóstico obtenido con la metodología ANFIS sin intervención de series exógenas y el pronóstico obtenido con ANFIS, afectado por las variables exógenas, resultado del Análisis de Componentes Principales.

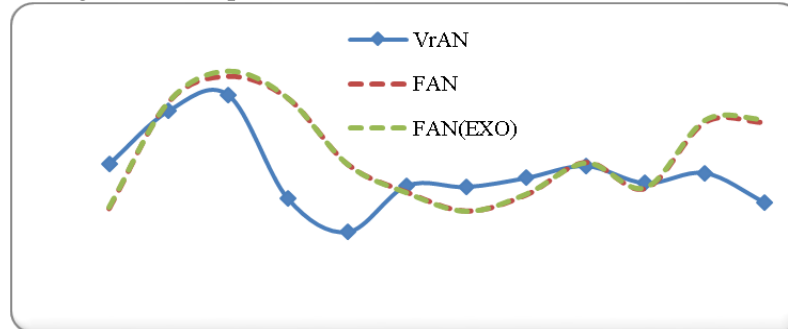
Figura 4a – Representación de la MAPE utilizando ANFIS



Fuente: Elaboración propia

Se puede observar que el pronóstico hallado por ANFIS – EXO, sigue en forma más ajustada a las ventas reales en el caso de AA y no presentan grandes diferencias en el caso de AN.

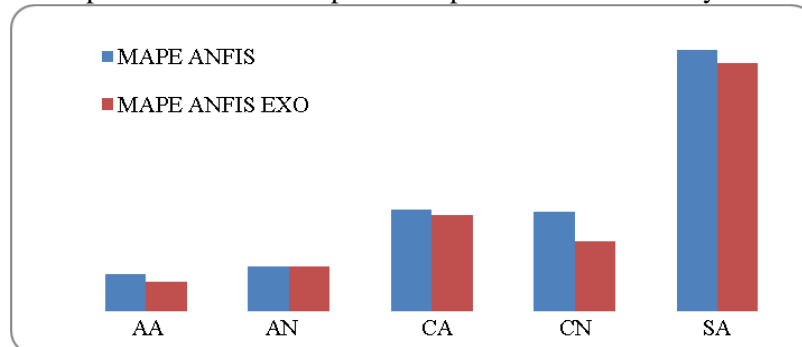
Figura 4b – Representación de la MAPE utilizando ANFIS – EXO



Fuente: Elaboración propia

En la Figura 5 se presentan las MAPE calculadas para los 5 productos, utilizando ANFIS y ANFIS - EXO. Se puede advertir que la MAPE es menor, cuando se aplican los resultados del Análisis de Componentes Principales para los casos analizados.

Figura 5 – Representación MAPE para cada producto con ANFIS y ANFIS – EXO



Fuente: Elaboración propia

No obstante en el caso de AN la disminución pasa prácticamente inadvertida. Este comportamiento se puede explicar a partir de la poca influencia que tienen las ventas de este producto en el conjunto de datos, tal como se puede concluir analizando la Tabla 2.

En Tabla 4 se presentan los valores de disminución de MAPE para los 5 productos, resultado de la diferencia entre la MAPE hallada para ANFIS y la de ANFIS – EXO.

Tabla 4 – Variación de MAPE aplicando variables exógenas

DELTA MAPE	
AA	-21,1209
AN	-0,0041
CA	-4,8390
CN	-29,7370
SA	-4,6796

Fuente: Elaboración propia

La disminución de MAPE en promedio es de alrededor del 12% lo que significa que las variables exógenas han influido de manera significativa.

5 CONCLUSIONES

Se aplicó el método ANFIS y ANFIS - EXO, para pronosticar las ventas de 5 productos pertenecientes a la industria conservera de la ciudad de Mar del Plata. Los datos y sus correspondientes pronósticos fueron tratados en forma mensual.

Los pronósticos se realizaron utilizando la metodología ANFIS y ANFIS afectado por variables Exógenas (ANFIS – EXO). Las variables exógenas se extrajeron de un Análisis Multivariado realizado al conjunto de todos los datos, en particular, aplicando el Análisis de Componentes Principales. A partir de dicho análisis se calcularon los coeficientes que afectaron las series de ventas, actuando como series exógenas. El método influido por las variables exógenas (ANFIS – EXO) arrojó menor MAPE para todos los casos analizados, comparado con el pronóstico hallado para ANFIS.

Resultados de trabajos anteriores, Corres et al. (2012), utilizaron como variables exógenas las ventas de productos con similares características, no arrojaron mejoras significativas en la precisión del pronóstico obtenido. No obstante, y como se observa en este trabajo, cuando las variables exógenas son adecuadas, contribuyen efectivamente a disminuir la MAPE.

Si bien, la MAPE del pronóstico con variables exógenas, realizado a AN disminuye, dicha disminución fue muy pequeña. Este comportamiento se pudo explicar a partir del Análisis de Componentes Principales.

El Análisis de Componentes Principales resultó una herramienta poderosa que permitió contribuir en forma apropiada a la elaboración de series exógenas. De acuerdo a los resultados hallados se puede concluir que, en este caso, la información contenida en las mismas, favoreció la performance del pronóstico.

El presente análisis se realizará con otras series de tiempo que revistan distintas características a las estudiadas, con la finalidad de evaluar el alcance en la obtención de conocimiento exógeno.

EXOGENOUS VARIABLES OBTAINING FOR IMPROVE FORECAST PERFORMANCE ACROSS MULTIVARIATE ANALYSIS

ABSTRACT: In this paper the behavior of a “soft computing” method is analyzed, to forecast sales of canned fish products from a local company. The sales were predicted for the last year, on a monthly basis and the real values were compared with those obtained. The forecasts were made using an Adaptive Neuro-Fuzzy Inference System (ANFIS); this methodology improves its performance when exogenous series are used properly. The prediction error was evaluated by the MAPE. From original dataset were derived exogenous series using Principal Component Analysis. The results indicate that the Principal Component Analysis proves to be a powerful tool that allows contributing properly to the development of exogenous series.

Keywords: Forecasting. Fish Canning Industry. Principal Components. ANFIS.

REFERENCIAS

AL SHAMI A, LOFTI A., COLEMAN S., DOSTÁL P. Unified knowledge economy hybrid forecasting. **Technological Forecasting & Social Change**. <http://dx.doi.org/10.1016/j.techfore.2014.01.014>, 2014

BALLOU R. **Logística:** Administración de la Cadena de Suministro. Quinta Edición, Capítulos 1 y 8, Editorial Prentice Hall, México, 2004.

BAYRAKTAR E., LENNY KOH S.C., GUNASEKARAN A., SARI K., TATOGLU E. The role of forecasting on bullwhip effect for E-SCM application. **International Journal of Production Economics**, v. 113, p. 193-204, 2008.

CHU Ch., ZHANG G. A comparative study of linear and nonlinear models for aggregate retail sales forecasting, **International Journal of Production Economics**, v. 86, p. 217-231, 2003.

CORRES G., ESTEBAN A., PASSONI I., ZÁRATE C. Pronóstico de Series de Tiempo usando métodos lineales y no lineales. Publicado en los **Anales XXIV ENDIO – XXII EPIO**, p. 314-326, 2011.

CORRES G., ESTEBAN A., ZÁRATE C. Aplicación de la Metodología ANFIS para la obtención de Pronósticos en Series de Tiempo: Evaluación del Costo del Error. Publicado en los **Anales XXV ENDIO – XXIII EPIO**, p. 15-27, 2012.

KENKEL N., DERKSEN D., THOMAS A., WATSON P. Multivariate Analysis in Weed Science Research. **Weed Science**, v. 50, p. 281-292, 2002.

QUINN G., KEOUGH M. **Experimental Design and Data Analysis for Biologists**. Chapter 17, CAMBRIDGE University Press, United Kingdom, 2002.

THOMASSEY S., HAPPIETTE M., CASTELAIN J. A global forecasting support system adapted to textile distribution. **International Journal of Production Economics**, v. 96, p. 81-95, 2005.

ZHANG P. Time series forecasting using a hybrid ARIMA and Neural Network Model. **Neurocomputing**, v. 50, p.159-175, 2003.

Originals recebidos em: 27/03/2014

Aceito para publicação em: 18/08/2014