

Extracción de reglas borrosas en problemas de clasificación multiatributo. El enfoque NEFCLASS

Javier Puente¹, David de la Fuente¹, Jesús Lozano¹, José Luis Herrero²

- ¹ Área Organización de Empresas. E.P.S. Ingeniería de Gijón. Universidad de Oviedo. Campus Viesques s/n 33204. Gijón. jpuente@etsiig.uniovi.es; david@etsiig.uniovi.es; lozano@etsiig.uniovi.es.
² Área Organización de Empresas. Universidad de Zamora. jltoranzo@usuarios.retecal.es.

Resumen

En este trabajo, se propone una nueva metodología para realizar clasificaciones tipo ABC multiatributo. Tradicionalmente, este tipo de problemas puede ser abordado desde una perspectiva estadística de análisis de datos, bien de modo univariante mediante clasificaciones Pareto, o de modo multivariante con técnicas de análisis cluster y métodos discriminantes. Posteriormente, diferentes herramientas de inteligencia artificial se propusieron para resolver este tipo de problemas de clasificación. En particular, el empleo de redes neuronales artificiales permite mejorar el comportamiento de clasificación a partir del aprendizaje de casos previos. No obstante, lo impenetrable de los modelos basados en redes neuronales, pese a su buen funcionamiento, hace que el modelo de clasificación subyacente no sea interpretable. Por ello, la extracción de reglas borrosas con el modelo NEFCLASS (NEuro Fuzzy CLASSification) a partir del aprendizaje de casos clasificados previamente, apunta una nueva vía de estudio en este sentido. Para comprobar la fiabilidad del modelo se realiza un análisis comparativo con la clasificación heurística realizada por un experto para un conjunto de 189 referencias mediante el análisis de cinco atributos de entrada y se analiza el conocimiento de clasificación obtenido con este sistema.

Palabras clave: Reglas Borrosas. Nefclass. Clasificación multiatributo.

1. Introducción

Aunque la clasificación ABC basada en el criterio de ordenación mediante el valor anual (Cohen y Ernst, 1988) está bastante extendida, existen otros criterios que pueden tener una gran significación a la hora de gestionar inventarios y que por lo tanto deberían ser incluidos a la hora de realizar clasificaciones. Ejemplos de estos criterios son el grado de caducidad, la criticidad de la referencia, el impacto de una rotura de stock de la misma, el coste de pedido, etc. (Silver, Pyke y Peterson, 1998). Algunos de estos criterios podrían llegar a tener más peso que el valor anual a la hora de planificar y controlar el inventario. Así, el responsable de la gestión de inventarios (experto), aunque suele tomar decisiones de control bastante efectivas basadas en reglas empíricas que consideran estos criterios al realizar la clasificación, no siempre será consistente en su determinación.

En (Puente y otros, 2003), se expuso la conveniencia de abordar el problema de clasificación ABC mediante redes neuronales artificiales para sistematizar y generalizar las decisiones de clasificación. Los resultados obtenidos con esta herramienta ponían de manifiesto el buen ajuste de la clasificación a la practicada heurísticamente por el experto en el problema clásico de clasificación propuesto por Partovi (2002).

No obstante, lo impenetrable de los modelos obtenidos para la clasificación multiatributo con redes neuronales artificiales, hace que sea conveniente encontrar modelos que mejoren la interpretabilidad de las clasificaciones que se pretendan realizar, por lo que las redes neuronales no resultan ser la mejor herramienta en este sentido.

En el presente trabajo, se muestra, en primer lugar, una descripción de las ventajas e inconvenientes del uso de las redes neuronales frente a los sistemas borrosos a raíz de la cual se plantea la fusión de ambas tecnologías a través de los llamados sistemas neuro-borrosos; a continuación, se describe la metodología Nefclass como sistema neuro-borroso para extraer conocimiento de clasificación en forma de reglas borrosas, a partir del aprendizaje de casos clasificados heurísticamente por un experto; por último, se aplica esta metodología a un problema clásico de clasificación y se analizan los resultados obtenidos frente a los conseguidos con otras técnicas tradicionales.

2. Los Sistemas Neuro-Borrosos

En la Tabla 1, se plasman los principales ventajas e inconvenientes de la utilización de redes neuronales artificiales y de los sistemas borrosos (Nauck, 1999):

Tabla 1. Comparación de redes neuronales y sistemas borrosos

Redes neuronales artificiales	Sistemas borrosos
Ventajas	
<ul style="list-style-type: none"> • No se requiere el modelo matemático del proceso. • No se requiere conocimiento en forma de una base de reglas. • Se dispone de diferentes algoritmos de aprendizaje. 	<ul style="list-style-type: none"> • No se requiere el modelo matemático del proceso. • Se puede usar información ya disponible sobre el proceso. • Fácil de implementar e interpretar
Desventajas	
<ul style="list-style-type: none"> • El sistema se comporta como una caja negra. • De la red entrenada no se puede extraer conocimiento en forma de reglas. • La adaptación a ambientes variables puede ser difícil y puede ser necesario volver a entrenar. • El conocimiento que se tenga a priori del proceso no puede ser utilizado durante el aprendizaje. • No hay garantías de que el aprendizaje converja. 	<ul style="list-style-type: none"> • Debe disponerse de una base de reglas. • No puede aprender. • No hay métodos formales para el ajuste de funciones de pertenencia. • Cuando se realizan estos ajustes, existen problema semánticos para interpretar los sistemas resultantes. • La adaptación a entornos variables puede ser difícil. • El ajuste puede no tener éxito.

Los sistemas neuroborrosos surgen para superar las desventajas de las redes neuronales y de los sistemas borrosos y el término neuroborroso se utiliza para referirse a cualquier clase de combinación entre ambas tecnologías. En la literatura consultada, existe cierto grado de confusión en la terminología empleada, usándose, entre otros, los siguientes términos: Hybrid neural net, regular fuzzy neural net, hybrid fuzzy neural net, fuzzy neural net, neural fuzzy net, neuro-fuzzy net, fuzzy-neuro net. Cada autor usa los diferentes términos para diferentes conceptos, pudiendo un mismo término tener diferente significado dependiendo del artículo consultado. En Takagi (2000), se recoge la estructura de diferentes modelos de sistemas neuroborrosos desde la perspectiva del nivel de fusión entre ambas tecnologías.

Los enfoques neuroborrosos constituyen una vía para encontrar de modo heurístico los parámetros de un sistema borroso a través del procesamiento de datos de ejemplos, sometidos a un algoritmo de entrenamiento. Deben considerarse como herramientas que ayudan a desarrollar modelos borrosos, pero no los crean de forma automática. La implementación de

un sistema neuro-borroso siempre debe permitir al usuario supervisar e interpretar el proceso de aprendizaje. Al igual que con las redes neuronales, el éxito del proceso de aprendizaje no está garantizado. Además, la solución que se persigue no debe ser evaluada exclusivamente en términos de obtención de un alto porcentaje de acierto en la clasificación de nuevos casos, si no también en términos de interpretabilidad y sencillez del modelo de clasificación resultante. Así, el usuario debería ser capaz de construir modelos con rapidez, probando diferentes configuraciones de parámetros (Nauck, 1999).

3. Metodología NEFCLASS

Nefclass (NEuro Fuzzy CLASSification) es una herramienta de tipo neuroborroso que permite obtener reglas de clasificación borrosas partiendo de un conjunto de datos etiquetados. Nefclass permite crear un clasificador borroso mediante algoritmos de aprendizaje estructurados en forma de reglas. Tras crear la base de reglas soporte del conocimiento de clasificación, Nefclass permite ajustar las funciones de pertenencia asociadas a las variables borrosas del modelo para posteriormente reducir la dimensión de la base de reglas mediante una estrategia de poda o pruning (Nauk y Kruse 1997, 1998, 1999).

Con la metodología NEFCLASS se pretende diseñar y/o ajustar un sistema borroso haciendo uso de una arquitectura en forma de red neuronal. La idea es introducir patrones de entrenamiento a la red de forma que el ajuste del sistema borroso se realice mediante un aprendizaje similar al obtenido con el algoritmo backpropagation de redes neuronales. NEFCLASS busca esencialmente sistemas interpretables y sencillos, en forma de reglas, de forma que se extraiga información de los datos y de esta forma conocer las relaciones existentes entre entradas y salidas. Por ello, usa sistemas de inferencia de tipo Mamdani, que son más intuitivos e interpretables y durante el aprendizaje, minimiza (en la medida de lo posible) el número de reglas borrosas, de variables de entrada, y de etiquetas lingüísticas. Esto suele ir en detrimento de la exactitud de la solución obtenida pero hace del modelo resultante un sistema claramente interpretable.

Tras revisar el estado actual del análisis de datos basado en técnicas Neuro-Borrosas y proponer su aplicación a problemas de clasificación ABC, se profundiza en la aplicación de la metodología específica de NEFCLASS al problema propuesto por Partovi (2002).

4. Aplicación de la metodología NEFCLASS a un problema clásico de clasificación. Resultados y Discusión

En este trabajo se propone el estudio de una base de datos correspondiente a 189 artículos de una empresa farmacéutica clasificados en categorías ABC según la heurística propia de un experto (Partovi, 2002), en función de los valores de cinco atributos valorados para cada ítem:

- a) Coste unitario (€): Coste que le supone a la empresa adquirir esa referencia.
- b) Demanda anual: Número de unidades de una referencia dada que circula por la empresa a lo largo de un año.
- c) Coste de pedido: Coste asociado a la reposición de material.
- d) Plazo de entrega (días): Tiempo que transcurre desde que se lanza el pedido hasta que entra en almacén.
- e) Criticidad del proceso (1-5): Grado de importancia del proceso al que pertenece esta referencia. A mayor importancia corresponde un valor mayor. Se habla de importancia referido a la gravedad que supone para el proceso, con la posibilidad de no poder

suministrar ítems al cliente. En cierto modo este atributo está relacionado con la gravedad de una rotura de stock.

En Puente y otros, (2003), se analizaron dos modelos de clasificación con objeto de optimizar el ajuste a la clasificación ABC realizada heurísticamente por el experto.

El primer modelo planteado “Método tradicional ABC” establece el ranking de clasificación de ítems en función de sólo dos atributos de entrada: coste unitario y demanda anual. La Tabla 2, muestra los resultados de clasificación obtenidos para las 189 referencias de partida.

Tabla 2. Matriz de confusión para una clasificación mediante el valor anual

	Clasificación resultante			Total
	A	B	C	
A	19 (59.4%)	11	2	32
B	9	25 (39.1%)	30	64
C	0	3	90 (96.8%)	93

Los resultados apuntaban que este método clasifica bien las referencias de tipo C pero no tan bien las de las clases A (59,4% de acierto) y B (39,1% de acierto). Se puede entonces considerar que no es una aproximación buena al tener una alta tasa de fallo en las categorías A y B consideradas como más importantes; así, parece necesario tener en cuenta el resto de atributos a la hora de buscar una clasificación óptima.

El segundo modelo planteado se basaba en la clasificación proporcionada por diferentes redes neuronales. Los resultados obtenidos, mostraron su mejor comportamiento relativo con la estructura 5-4-4-3, en la que tanto el porcentaje de acierto en los casos de entrenamiento, validación, y total, superaban los promedios de porcentaje de acierto de todas las estructuras probadas, a la par que se obtenían las mejores clasificaciones en el conjunto de validación. A la vista de los resultados, se comprueba que la clasificación conseguida con esta tipología de red se ajusta con bastante buena precisión a la obtenida por la heurística del experto (Ver Tabla 3).

Tabla 3. Porcentajes de clasificación correcta de la mejor estructura de red encontrada.

	Total	A	B	C
% Referencias bien clasificadas del inventario completo	83,3%	73,8%	75,9%	91,6%

Sin embargo, a pesar de los buenos resultados obtenidos con la red neuronal, el conocimiento de clasificación queda oculto en el propio modelo de pronóstico de la red, por lo impenetrable de su estructura (caja negra). Por esta razón, se estudió la posibilidad de crear un modelo de clasificación para este problema con la utilización de la metodología NEFCLASS como técnica neuro-borrosa que permitiese poner de manifiesto el conocimiento de clasificación aprendido de los casos clasificados por el experto.

La operativa con Nefclass es la siguiente: primero, se realiza una primera pasada sobre los patrones de aprendizaje con el propósito de determinar un sistema de reglas borrosas inicial. Posteriormente se pasará sucesivamente el conjunto de patrones, divididos en un conjunto de entrenamiento y otro de validación, de forma que mediante aprendizaje se optimicen las funciones de pertenencia para mejorar la clasificación. Por último habrá una etapa de poda o pruning del sistema, para simplificarlo y proporcionarle un mayor interpretabilidad.

Las características aplicables al procesamiento con NEFCLASS para este problema pueden resumirse en los siguientes puntos:

- Previo al entrenamiento con NEFCLASS se ha procedido a preprocesar las entradas relativas al Coste unitario y la Demanda anual aplicándoles la función $\ln(x+1)$ para reducir el rango de su dominio (grande debido a unos pocos valores). El resto de entradas no se preprocesa.
- Al crear el sistema de reglas borrosas, se limita a 10 como máximo el número de reglas que formarán la base, y el criterio de selección de las mismas será el de las mejores reglas borrosas por clase. Se formarán por cada atributo de entrada tres conjuntos borrosos (PEQUEÑO, MEDIANO y GRANDE).
- Durante la optimización de los conjuntos borrosos identificables en las reglas, se entrenará con los ejemplos durante 500 ciclos o bien hasta que el error del conjunto de validación comience a crecer.
- Se han impuesto las siguientes restricciones para que el sistema sea lo más interpretable posible: que se mantenga el orden relativo de los conjuntos borrosos entre sí; que siempre haya solape entre, al menos, dos conjuntos borrosos y, por último, que la intersección entre dos conjuntos siempre se produzca al nivel 0.5.
- Posteriormente se realizará un recorte del sistema de reglas con el objeto de simplificar el clasificador para que sea más interpretable.

Las tablas 4.1, 4.2 y 4.3 muestra los resultados obtenidos al entrenar y validar un sistema NEFCLASS con cinco diferentes parejas de conjuntos entrenamiento-validación, de 129 y 60 casos respectivamente:

Tabla 4.1. Resultados de clasificación en el proceso de entrenamiento (129 casos).

Sistema	Entrenamiento								
	A			B			C		
	A	B	C	A	B	C	A	B	C
1	13	9	0	7	28	9	0	12	51
2	13	9	0	6	33	5	0	19	44
3	20	2	0	17	22	5	2	14	47
4	13	9	0	6	31	7	0	15	48
5	12	10	0	8	25	11	0	12	51

Tabla 4.2. Resultados de clasificación en el proceso de validación (60 casos).

Sistema	Validación								
	A			B			C		
	A	B	C	A	B	C	A	B	C
1	7	3	0	2	15	3	0	8	22
2	6	4	0	3	13	4	1	7	22
3	10	0	0	7	9	4	0	6	24
4	5	5	0	1	14	5	0	5	25
5	2	8	0	2	15	3	0	6	24

Se observa que los resultados en cuanto a clasificación no son tan buenos como los obtenidos mediante las redes neuronales. Se ha sacrificado precisión (debido a las restricciones impuestas en diferentes puntos del algoritmo) para obtener conocimiento en forma de reglas interpretables.

Haciendo balance de los cinco sistemas obtenidos, se puede observar que:

En dos de los cinco sistemas, las reglas resultantes están formadas por las variables **criticidad**, **demanda anual** y **plazo de entrega**. En otros dos sistemas, las reglas están

formadas por las variables **criticidad** y **demanda anual**. Por último, en el último sistema interviene únicamente la variable **criticidad**.

Tabla 4.3. Resultados de clasificación detallados para el sistema NEFCLASS

Sistema	Entrenamiento				Validación			
	Total	A	B	C	Total	A	B	C
1	71,3%	59,1%	63,6%	81,0%	73,3%	70,0%	75,0%	73,3%
2	69,8%	59,1%	75,0%	69,8%	68,3%	60,0%	65,0%	73,3%
3	69,0%	90,9%	50,0%	74,6%	71,7%	100,0%	45,0%	80,0%
4	71,3%	59,1%	70,5%	76,2%	73,3%	50,0%	70,0%	83,3%
5	68,2%	54,5%	56,8%	81,0%	68,3%	20,0%	75,0%	80,0%
Media	69,9%	64,5%	63,2%	76,5%	71,0%	60,0%	66,0%	78,0%

	Total	A	B	C
% Referencias bien clasificadas del inventario completo	70,3%	63,1%	64,1%	77,0%

Se concluye entonces que los atributos más importantes a la hora de hacer la clasificación son **criticidad**, **demanda anual** y **plazo de entrega**, en este orden. El resto de atributos parecen menos importantes a la hora de hacer la clasificación.

A continuación se muestra el sistema donde interviene sólo la criticidad, y que se corresponde con el sistema 3 indicado en la tabla anterior:

- R1: Si (*Criticidad es GRANDE*) entonces A.
- R2: Si (*Criticidad es MEDIANO*) entonces B.
- R3: Si (*Criticidad es PEQUEÑO*) entonces C.

Las funciones de pertenencia obtenidas, asociadas a la variable criticidad fueron las indicadas en la Figura 1.

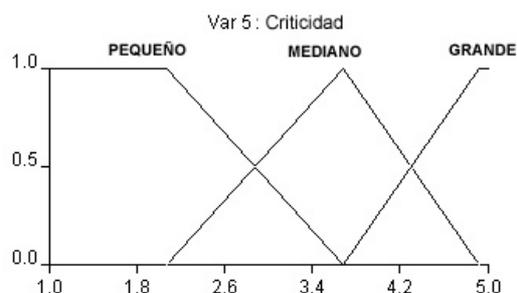


Figura 1. Funciones de pertenencia para la variable criticidad

Se aprecia cómo las restricciones impuestas han modelado las funciones de pertenencia de modo que tras el aprendizaje, el orden relativo (pequeño-mediano-grande) se ha mantenido, y las funciones de pertenencia se cortan en el nivel 0.5 (esta restricción implica que al menos dos conjuntos – y sólo dos – se solapan).

5. Conclusiones

Los resultados obtenidos al aplicar la metodología NEFCLASS al problema de clasificación propuesto por Partovi (2002), se muestran resumidos en la Tabla 5, comparativamente a los obtenidos mediante un modelo de red neuronal. Aunque la precisión es menor con NEFCLASS, se consigue identificar el conocimiento de la clasificación en forma de reglas borrosas, identificándose como variables relevantes: la criticidad, la demanda anual y el plazo

de entrega, en este orden. El resto de atributos parecen menos significativos a la hora de efectuar la clasificación.

Tabla 5. Resultados de clasificación comparativos

	Total	A	B	C
% Referencias bien clasificadas NEFCLASS	70,3%	63,1%	64,1%	77,0%
% Referencias bien clasificadas RED NEURONAL	83,3%	73,8%	75,9%	91,6%

A la vista de estos resultados, parece posible generalizar el buen comportamiento de la metodología NEFCLASS para problemas de clasificación multiatributo. Este esquema, permite aunar en una misma herramienta: unos buenos resultados clasificatorios (aunque no tanto como con una red neuronal pura) junto con el conocimiento de clasificación extraído en forma de reglas borrosas de decisión.

Referencias

- Cohen, M. A., & Ernst, R. (1988). Multi-item classification and generic inventory stock control policies. *Production and Inventory Management Journal*, 29 (3), 6-8.
- Nauck, U. (1999). "Design and Implementation of a Neuro-Fuzzy Data Analysis Tool In Java" Ph.D. Tesis, Technische Universität Braunschweig, 1999.
- Nauck, D. and Kruse, R. (1997). A Neuro-Fuzzy Method to Learn Fuzzy Classification Rules from Data. *Fuzzy Sets and Systems*, 89:277–288.
- Nauck, D. and Kruse, R. (1998). NEFCLASS-X – A Soft Computing Tool to Build Readable Fuzzy Classifiers. *BT Technology Journal*, 16(3):180–190.
- Nauck, D. and Kruse, R. (1999). Obtaining Interpretable Fuzzy Classification Rules from Medical Data. *Artificial Intelligence in Medicine*, 16 (2): 149-169.
- Partovi F.Y., Anandarajan, M. (2002) "Classifying inventory using an artificial neural network approach". *Computers and Industrial Engineering*. 41. pp. 389-404.
- Puente J.; Priore, P.; Pino, R.; de la Fuente, D. (2003). "La clasificación ABC multiatributo de inventarios con técnicas de Inteligencia Artificial". *V Congreso de Ingeniería de Organización*. Valladolid.
- Silver, E. A., Pyke, D. F., & Peterson, R. (1998). Inventory management and production planning and scheduling. *New York: Wiley*.
- Takagi, H. (2000). Fusion technology of Neural Networks and Fuzzy Systems: a chronicled progression from de laboratory to our daily lives. *International Journal of Applied Mathematics and Computer Science*. 10 (4), 647-673.