

Revisión del uso de la lógica difusa aplicada a modelos de puntuación crediticia

A review of fuzzy logic applied to credit scoring models

Sebastián Gómez Jaramillo
Estudiante Maestría en Ingeniería
Ingeniería de Sistemas
sgomezj@unal.edu.co
Universidad Nacional de Colombia
– Sede Medellín – Facultad de Minas

Recibido: 1 de marzo 2012
Aprobado: 30 de marzo 2012

Resumen

La lógica difusa tiene una gran variedad de aplicaciones, especialmente en la toma de decisiones. Uno de los campos donde se está empezando a aplicar es en el bancario, que en los últimos años sufrió un gran golpe debido a la crisis financiera. El presente estudio analiza los modelos de scoring crediticio los cuales permiten a los bancos pronosticar el comportamiento de pago de un cliente. En este modelo se han realizado trabajos principalmente mediante modelos estadísticos y el uso de redes neuronales, pero últimamente también han incursionado los estudios de lógica difusa en este campo. En el artículo se encuentran estudios diferentes, aplicando lógica difusa con diferentes enfoques, todos con resultados positivos.

Palabras claves: Lógica difusa, *scoring* crediticio, préstamo bancario.

Abstract

Fuzzy logic has a wide variety of applications, especially in decision-making. One of the areas where it is beginning to be applied is in the banking field, which in recent years suffered the financial crisis. This study examines the credit scoring models which allow banks to make payment to predict client's behavior. In this model, work has been done primarily through the use of statistical models and neural networks, but it has recently entered fuzzy logic studies in this field. This paper includes different studies, using fuzzy logic with different approaches, all with positive results.

Keywords: Fuzzy logic, credit scoring, bank loan.

1. Introducción

En los últimos años se ha vuelto común encontrar en periódicos de diferentes países artículos dedicados a las crisis financieras, tanto por problemas locales como globales. Dichas crisis alcanzan tal magnitud que han llevado a países enteros a la ruina (Sánchez, 2009). Entre los problemas que han afrontado los bancos, se destaca el generado por los préstamos impagados de sus clientes; parte de este problema se debe a un mecanismo erróneo de otorgamiento de créditos, sin considerar la capacidad de endeudamiento real del usuario. Por este motivo, se considera de vital importancia realizar estudios para mejorar la efectividad al momento de otorgar créditos a los clientes.

Uno de tales métodos es el denominado *modelo de puntuación crediticia* o *score*, que permite pronosticar el comportamiento de pago de un cliente, analizando sus características y su historial de endeudamiento. Para determinar la puntuación, se han utilizado principalmente dos tipos de modelos: uno basado en estadística y el segundo mediante el uso de redes neuronales artificiales. Sin embargo, también han surgido otras técnicas complementarias para mejorar la efectividad en el cálculo.

Dentro de las técnicas emergentes que han sido utilizadas se encuentra la lógica difusa, la cual permite obtener resultados más robustos debido a la posibilidad de utilizar variables ambiguas de una manera adecuada, además por el uso de lenguaje natural ofrece la posibilidad de hacer interpretaciones familiares al vocabulario tanto del cliente como de los empleados del banco. Otra de las grandes ventajas ofrecidas por la lógica difusa, es la posibilidad de usarse de manera complementaria con otras técnicas, como los algoritmos evolutivos, las redes neuronales, los agentes de software, entre otros.

El presente artículo realiza una revisión de tema, de la aplicación de la lógica difusa en el cálculo de la puntuación crediticia. Partiendo de un marco teórico sobre el modelo de score, incluyendo una breve explicación sobre cómo se calcula en

la actualidad, seguido de una introducción a la lógica difusa. Posteriormente se realiza la revisión del tema, con la aplicación de lógica difusa en ocho casos de estudio, incluyendo su uso en conjunto con otras técnicas diferentes.

2. Marco teórico

Modelo de score

Dentro de las funciones de una entidad bancaria está otorgar créditos a sus clientes. Este proceso reviste gran complejidad debido a las variables que se deben considerar; por lo tanto, esta función no puede definirse simplemente por la interpretación del analista. Debido a esto, surgió la necesidad de encontrar mecanismos que pudiesen predecir el comportamiento de pago de los clientes. Uno de los utilizados es el denominado modelo de *score*, que se define a continuación:

Scoring se refiere al uso de conocimiento sobre el desempeño y características de préstamos en el pasado para pronosticar el desempeño de préstamos en el futuro. Así, cuando un analista de crédito valora el riesgo comparando mentalmente una solicitud de crédito en el presente con la experiencia que este mismo analista ha acumulado con otros clientes con solicitudes parecidas (Schreiner, 2002).

Esto quiere decir que se utiliza el *scoring*, como método para pronosticar el comportamiento de pago de un cliente con base en datos históricos y patrones de comportamiento del usuario, como la capacidad de pago, garantías del préstamo, condiciones económicas, historia crediticia, entre otros. La principal función es la predicción, de modo que, su función es reducir la incertidumbre en el otorgamiento de créditos bancarios.

Para calcular el puntaje (*score*), se utilizan principalmente dos técnicas: la primera cuantitativa y la segunda cualitativa. La primera, forma origi-

nal de cálculo, es con base en métodos estadísticos, calculando el riesgo crediticio asignando probabilidades, partiendo de una base de datos y suponiendo que el futuro va a mantenerse igual. Los métodos estadísticos tienen grandes ventajas; por ejemplo, pueden hacer predicciones con base en distintas variables, así como expresar el riesgo en una probabilidad. Sin embargo, su principal dificultad radica en la necesidad de contar con una base de datos de créditos anteriores muy robusta para que sus resultados tengan un buen ajuste a la realidad. Otra dificultad se genera debido a que las interpretaciones están hechas con base a características cuantificables, lo que no permite determinar la proporción en que el riesgo está asociado a cada una de estas variables. De todos modos, en la actualidad los métodos estadísticos siguen siendo la forma principal de calcular el *scoring* crediticio.

La segunda técnica más utilizada en el modelo de *score* son las redes neuronales, definidas como:

formas de modelar el proceso de decisión como un sistema de unidades de procesamiento conectadas entre sí. Aquí, cada unidad recibe un input y produce un output. Así sí, los inputs son las características del cliente y el output es su desempeño crediticio (Dabos, 2010).

Adicionalmente existen gran cantidad de metodologías diferentes, como lo indica Gutiérrez:

Para evaluar el riesgo crediticio o la conveniencia de otorgar un crédito, hay una gran variedad de metodologías disponibles análisis discriminante, regresión lineal, regresión logística, modelos probit, modelos logit, métodos no paramétricos de suavizado, métodos de programación matemática, modelos basados en cadenas de Markov, algoritmos de particionamiento recursivo (árboles de decisión), sistemas expertos, algoritmos genéticos, redes neuronales y, finalmente, el juicio humano (Gutiérrez, 2007).

En la revisión presentada en este artículo, se utilizan varias de estas metodologías en conjunto con la lógica difusa.

Lógica difusa

La lógica difusa surge casi como un nuevo paradigma de ver el mundo, porque establece una gran diferencia con la lógica convencional, donde todo está basado en unos y ceros, el mundo es blanco o negro. Mientras tanto, con la lógica difusa se presenta una escala de grises; en otras palabras, incluye una vaguedad entre los aspectos que evalúa, debido a lo impreciso de la naturaleza, Y especialmente, a lo complejo del pensamiento de los hombres. Esto último se puede considerar como la finalidad de la lógica difusa, la cual es tener una lógica aproximada al pensamiento real del ser humano, usando un lenguaje natural y unas variables lo suficientemente amplias y vagas como para ser consideradas naturales. Además permite generar ambigüedad entre los conceptos de varias personas. A manera de ejemplo, una persona A considera que un humano es alto si mide 1,80 metros de estatura; sin embargo para una persona B, los humanos son considerados altos si miden desde 1,70 metros (ver figura 1). Partiendo de la ambigüedad presentada por el razonamiento de ambas personas, la lógica difusa genera un análisis poder definir en qué grado de pertenencia se considera alta una persona. A continuación se presenta una definición de lógica difusa:

Un conjunto difuso se encuentra asociado por un valor lingüístico que está definido por una palabra, etiqueta lingüística o adjetivo. En los conjuntos difusos la función de pertenencia puede tomar valores del intervalo entre 0 y 1, y la transición del valor entre cero y uno es gradual y no cambia de manera instantánea como pasa con los conjuntos clásicos (Ramírez, 2008).

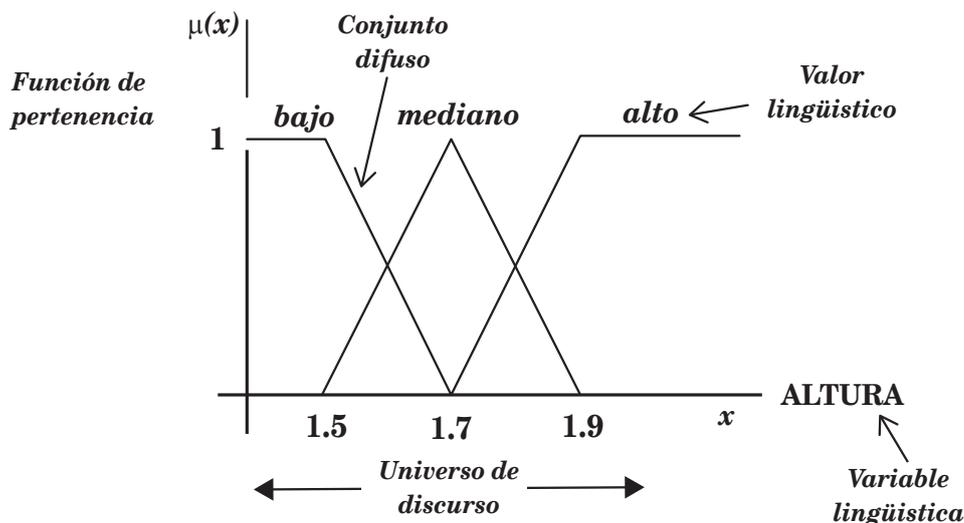


Figure 1. Ejemplo de conjunto difuso (Ramírez, 2008)

El uso de la lógica difusa es bastante amplio, debido a que tiene un campo de aplicación generalizado a casi cualquier área del conocimiento donde se necesite hacer un análisis o tomar decisiones. La lógica difusa debe usarse en procesos complejos cuando no existe un modelo matemático que lo pueda definir. También es útil cuando se necesita la ayuda de uno o varios expertos debido a que sus conocimientos pueden ser ambiguos e imprecisos (Mathworks, 2007).

3. Revisión de casos de aplicación en el cálculo de *score crediticio* mediante el uso de la lógica difusa

La lógica difusa puede usarse de manera independiente o combinarse con muchas otras técnicas, principalmente del denominado “*soft-computing*”, que incluye las redes neuronales, los algoritmos evolutivos, las redes bayesianas, entre otras.

A continuación se muestran diferentes aplicaciones realizadas con lógica difusa, utilizando me-

todologías diferentes o mezclando técnicas en conjunto con la difusa.

ARTMAP Fuzzy

El primer caso es una combinación de lógica difusa con un modelo de red neuronal denominado ARTMAP Fuzzy (FAM, por sus siglas en inglés). Se usa debido a la capacidad de tener un aprendizaje incremental y de eliminar el dilema plasticidad-estabilidad, el cual consiste en aprender nuevos patrones (plasticidad del aprendizaje) y poder retener dichos patrones durante el tiempo (estabilidad del aprendizaje).

Este sistema de aprendizaje supervisado es construido a partir de un par de módulos de ART que son capaces de auto-organizar categorías estables utilizando las operaciones de la teoría de conjuntos difusos, generando una ventaja sobre otras redes neuronales.

El modelo de ARTMAP Fuzzy fue probado satisfactoriamente en un caso real en Australia (Sasu, 2010), demostrando que es un método muy acertado cuando se utiliza para calcular probabilidades de pago, debidado a la clasificación y a la estimación de probabilidades que genera.

Modelo simple de puntuación difusa (FS-Score)

El FS-Score se ha comparado con otros cuatro modelos, analizando cuál de todos obtiene una puntuación y una probabilidad más cercana a la realidad, utilizando un caso de estudio basado en la crisis financiera rusa. Los otros modelos comparados fueron: el modelo de corte simple (S-Score), el logístico (Logit) y el basado en variables difusas (F Logit). La conclusión del investigador fue que: "Los modelos son bastante similares en términos de su poder predictivo. FS-Score y F Logit son un poco más de gran alcance. Aunque FS-Score es también más sencillo" (Ivliev, 2010).

Así, el autor concluye que el FS-Score da una buena explicación de la crisis generada por el incumplimiento en los pagos de los créditos, debido a que no está en capacidad de predecir cambios en el ciclo económico. El modelo puede arrojar una mejor aproximación realizándole un seguimiento a lo largo del tiempo y por diferentes sectores de la economía, o si se contara con un mayor número de variables asociadas a los prestatarios.

Puntuación crediticia difusa

El estudio presentado en este artículo se basa en el modelo que actualmente usa Taiwán para calcular el riesgo crediticio, el cual fue establecido por la "Bank Association of Taiwan" en 1987. En dicho país generalmente se utilizaban "tablas de evaluación de crédito" para establecer el riesgo y los montos del crédito, pero estas tablas suelen no tener en cuenta "la naturaleza difusa" de las variables introducidas en el problema de asignación de créditos. Con el modelo *fuzzy credit rating*, plantearon la necesidad de modular el sistema con base en el conocimiento profesional y la experiencia de expertos en préstamos para establecer las normas y los hechos con las que funciona el software, garantizando que el sistema sea bien aplicado.

Los autores describen su técnica de la siguiente forma:

una técnica de fusión pruebas, el fuzzy integral, que se emplea para agrupar la información de crédito teniendo en cuenta no sólo las pruebas, con el apoyo de los criterios de evaluación financiera, sino también su importancia relativa. Una estructura jerárquica de base es una unidad fundamental para obtener la información asociada a la calificación crediticia. Los nodos hijos son fuentes de conocimiento que proporcionan un conjunto de pruebas para su nodo principal en una estructura jerárquica de base. Los resultados de la evaluación del nodo principal se determinan teniendo en cuenta tanto las pruebas objetivas y la importancia relativa de cada nodo hijo (Chen & Chiou, 1999).

Asimismo resaltan la importancia de definir las variables sobre funciones de conjuntos borrosos, debido a que esta característica ayuda en una gran escala a darle dinamismo al modelo, aspecto de gran importancia por la variabilidad que pueden presentar los diferentes casos de asignación de créditos.

TOPSIS

Se plantea la necesidad que tienen los bancos de Turquía de realizar una rápida clasificación de los clientes en dos grupos "los que necesitan de un análisis más profundo" y "los que necesitan de un análisis rápido", la apropiada asignación a un grupo u otro permite al banco optimizar sus costos y asignar recursos al público en general.

Los autores proponen la utilización del modelo COSEL para separar estos dos grupos. En el desarrollo del modelo se utilizaron siete diferentes indicadores económicos de veintidós empresas manufactureras extraídos principalmente de fuentes gubernamentales.

Se utilizó el modelo TOPSIS (por sus siglas en inglés), donde se le asignó el peso a cada variable dependiendo de su importancia dentro de

un conjunto de números borrosos (la asignación se hizo por medio del criterio de expertos). Los resultados del experimento arrojaron que el programa puede aliviar en gran medida la carga de trabajo y optimizar la asignación de recursos por parte de los bancos en el estudio de solicitudes de crédito (Tansel & Yurdakul, 2010).

Modelo Knn

En este artículo se propone un modelo difuso basado en clasificadores. Primero, la regla base es aprendida mediante el entrenamiento de datos usando el método denominado SOM (*self-organization map*), el cual consiste en extraer una base de reglas difusas para diseñar el primer clasificador. Luego se incorpora el clasificador k-nn que sirve para integrar la información del contexto con la de entrenamiento, generando una

clasificación más robusta y cuantitativamente mejor.

Originalmente el clasificador K-nn encuentra el punto k más cercano al punto que va a ser clasificado en el espacio de características del conjunto de entrenamiento, luego clasifica el punto a la clase donde la mayoría de los vecinos quedan cerca. Posteriormente esa clasificación se usa para la elaboración de reglas difusas, en lo que se denomina FRKNN.

El propósito del modelo es establecer un desarrollo real de scoring crediticio y que además pueda ser incorporado de forma fácil. En la figura 2. Se observa el modelo de aprendizaje del sistema, que empieza con un entrenamiento de datos, luego se elabora el clasificador mediante el SOM, seguido a esto se utiliza un prototipo denominado Dynamic Generation, pasa luego por la extracción de reglas difusas y finalmente se aplica el clasificador k-nn.

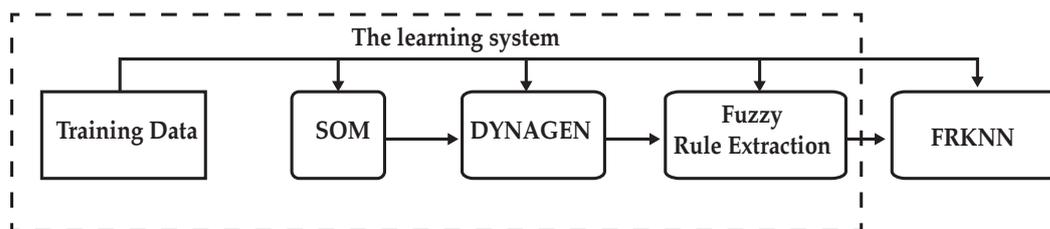


Figure 2. Modelo FRKNN (Laha, 2007)

Lógica difusa basada en agentes

Otra propuesta es la descrita por Yu, Wang y Lai (2009) en donde combinan agentes inteligentes con lógica difusa para la toma de decisiones. En primera instancia analizan y evalúan los riesgos crediticios basados en unos criterios predefinidos. Posteriormente, los resultados arrojados son generados por diferentes agentes inteligentes, utilizando la metodología de decisiones tomadas en grupo (GDM, por sus siglas en inglés), donde cada agente experto expresa su opinión sobre el riesgo crediticio, creando datos para ser *fusificados*. Finalmente estas opiniones se agregan dentro de un grupo consensuado por el GDM para pasar a ser desfusificado y gene-

rar una decisión final sobre el crédito. La ventaja que tiene el modelo es que no solo se basa en la opinión de un experto, sino que la decisión se toma de forma colaborativa, lo que permite analizar un mayor número de criterios. El estudio está aplicado a tres casos reales diferentes: uno en Japón, otro en Alemania y el tercero en el Reino Unido, demostrando así que la técnica tiene un gran potencial dentro del área.

Lógica difusa y algoritmos evolutivos

Este trabajo propone dos tipos de reglas de aprendizaje en algoritmos difusos evolutivos. Una con reglas difusas aproximadas y otra des-

criptiva. La primera creada mediante una estrategia evolutiva y la segunda extraída mediante algoritmos genéticos.

Las reglas descriptivas comparten conjuntos difusos con etiquetas lingüísticas; por lo tanto son más fáciles de interpretar, mientras que las reglas aproximadas se utilizan dentro de las funciones de pertenencia. El algoritmo evolutivo pretende cubrir todos los ejemplos de entrenamiento. De esta manera, primero se escoge un subconjunto de los ejemplos; luego se analiza una nueva regla difusa y se eliminan del conjunto de entrenamiento los casos que coincidan con esta regla para analizar un nuevo conjunto, hasta que

el objetivo esté cumplido. Después de generar una regla difusa, se cambia la distribución del entrenamiento basado en el error observado en la iteración anterior. El resultado final debe ser encontrar las reglas de clasificación que mejor describan la distribución de los ejemplos de entrenamiento. Para probar el rendimiento del algoritmo se utilizaron dos casos de estudios con resultados favorables en términos de la precisión en la clasificación de las reglas de aprendizaje.

En la figura 3, se observa la estructura del algoritmo, en donde se da el paso del entrenamiento a la generación de las reglas difusas mediante los algoritmos genéticos.

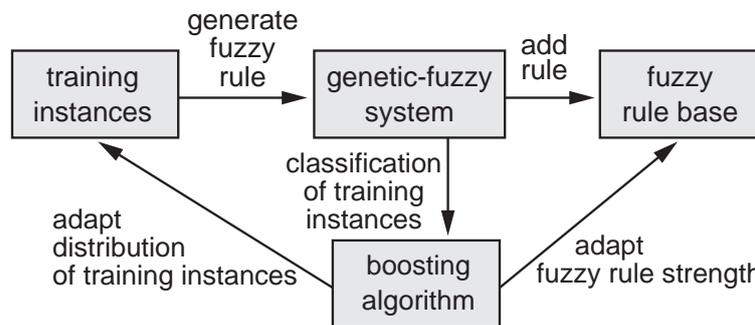


Figure 3. Modelo basado en algoritmos evolutivos (Hoffmann, Baesens, Mues, Gestel, & Vanthienen, 2007)

4. Conclusiones

Los modelos que incluyen lógica difusa han obtenido resultados satisfactorios en el cálculo del *scoring* crediticio, por lo cual se consideran una opción válida para la implementación en corto tiempo en diferentes bancos de todo el mundo.

La lógica difusa complementa de manera pertinente los modelos existentes, ayudando a obtener mayor detalle para el cálculo del puntaje crediticio, tanto de forma cuantitativa como cualitativa. Además permite mejorar la comunicación entre el cliente y el banco, debido a las facilidades del lenguaje otorgadas por la lógica difusa.

Referencias

- [1] Chen, L.-H., & Chiou, T.-W. (1999). A fuzzy credit-rating approach for commercial loans: a Taiwan case. *Omega*, 407-419.
- [2] Dabos, M. (2010, Noviembre 2). *Materia Biz*. Recuperado: 30 de mayo, 2011, from <http://www.materiabiz.com/mbz/economiayfinanzas/nota.vsp?nid=44224>
- [3] Gutiérrez, M. (2007). *Credit scoring models: what, how, when and for what purposes*. Buenos Aires: Banco Central de la República de Argentina.
- [4] Hoffmann, Baesens, Mues, Gestel, V., & Vanthienen. (2007). Inferring descriptive and approximate fuzzy rules for credit scoring using evolutionary algorithms. *European Journal of Operational Research*, 540-555.

- [5] Ivliev, S. (2010). Simple Fuzzy Score for Russian Public Companies Risk of Default . *Cornell University Library*.
- [6] Laha, A. (2007). Building contextual classifiers by integrating fuzzy rule based classification technique and k-nn method for credit scoring. *Advanced Engineering Informatics* 21 , 281–291.
- [7] Mathworks, T. (2007). *Fuzzy Logic Toolbox 2*. The Mathworks.
- [8] Ramírez, O. (2008). Lógica Difusa. En O. Ramírez, *Simulación en simmechanics de un sistema de control difuso para el robot udlap* . Puebla: Universidad de las Américas Puebla.
- [9] Sánchez, L. B. (2009). Un paseo por la crisis económica mundial. *Economía Autónoma*. Disponible en línea: <http://www.eumed.net/rev/ea/03/lbss.htm#>.
- [10] Sasu, L. (2010). Fuzzy Artmap for credit Scoring. *Bulletin of the Transylvania University of Brasov*.
- [11] Schreiner, M. (2002). Ventajas y desventajas del scoring crediticio en las microfinanzas. *Microfinancerisk Management*, Washington University de St. Louis, pp. 1-40.
- [12] Tansel, Y., & Yurdakul, M. (2010). Development of a quick credibility scoring decision support system using fuzzy TOPSIS. *Expert Systems with Applications* 37, 567-574.
- [13] Yu, L., Wang, S., & Lai, K. K. (2009). An intelligent-agent-based fuzzy group decision making model for financial multicriteria decision support: The case of credit scoring. *European Journal of Operational Research*, 942-959.