

PREVISIÓN DE INSOLVENCIA UTILIZANDO TÉCNICAS DE MINERÍA DE DATOS: APLICACIÓN EN UNA EMPRESA DE DISTRIBUCIÓN DE ENERGÍA ELÉCTRICA

*Juan Lazo Lazo, Departamento de Ingeniería, Universidad del Pacífico,
Lima-Peru, jg.lazol@up.edu.pe*
*Edgardo R. Bravo, Departamento de Ingeniería, Universidad del Pacífico,
Lima-Peru, er.bravooo@up.edu.pe*

RESUMEN

La insolvencia es un problema relevante que confrontan las organizaciones en general, y las de distribución eléctrica en particular, más aún en contextos de alta competencia y entornos de crisis o de fluctuaciones económicas importantes. Si bien los modelos de evaluación de crédito se han desarrollado en el ámbito bancario, es escaso el desarrollo de modelos similares en empresas de servicio y, específicamente, de distribución eléctrica.

En esa medida, este artículo desarrolla un método capaz de identificar la posible insolvencia de los clientes de una distribuidora de energía eléctrica, utilizando técnicas de inteligencia computacional a partir del análisis de datos e indicadores económicos que afectan al cliente.

El método se basa en dos etapas: la primera, implica una categorización para agrupar unidades consumidoras con patrones de actividades económicas similares; y la segunda, una clasificación para descubrir cambios en el perfil de comportamiento de los clientes, configurando la posibilidad de insolvencia.

Los resultados obtenidos con el modelo fueron considerados muy buenos por especialistas responsables del área de análisis de facturación de grandes clientes en la empresa distribuidora.

Palabras clave

Prevención de insolvencia, Clustering, Clasificación, Redes Neuronales, Data Mining.

INTRODUCCIÓN

El escenario latinoamericano, inserto en el proceso de globalización y sujeto a oscilaciones económicas importantes, crea situaciones de dificultades financieras para varios segmentos comerciales, industriales y de servicios. Saber identificar correctamente a los clientes con alto riesgo de insolvencia permite optimizar la inversión dentro de las organizaciones en la prevención y recuperación de las pérdidas comerciales.

Si bien en el campo bancario existe un avance importante en modelos de riesgo crediticio (Anagnostopoulos & Abedi, 2016; Doumpos & Zopounidis, 2014), una diferencia sustancial con empresas de otros servicios en general, y de distribución eléctrica en particular, es que los primeros disponen de información financiera detallada de sus prestamistas mientras que los últimos no.

Los diversos factores que deben ser tomados en cuenta en la gestión de la insolvencia de una cartera de clientes no son totalmente previsibles, de tal forma que una toma de decisión en este contexto es siempre una tarea compleja. Para ayudar en la prevención de incumplimiento e, incluso, en la recuperación de los ingresos, muchas técnicas computacionales clásicas (p.e. programación matemática) han sido aplicadas, todavía con resultados insatisfactorios. Esto debido, básicamente, a que las empresas de distribución tienen información financiera limitada del cliente; y a la influencia de factores externos.

Este artículo describe la aplicación de la inteligencia computacional para clasificar la cartera de clientes en clústeres o grupos de nivel de riesgo de insolvencia. De esa forma, será posible direccionar las acciones de pre-cobranza, cobranza de débitos efectivos y la adopción de medidas preventivas, y se mini-

mizarán los costos asociados a través del direccionamiento de los recursos para los grupos con mayor riesgo, con la finalidad de reducir las pérdidas.

En ese sentido, fueron evaluadas diversas técnicas de inteligencia computacional para modelar estas características a partir de factores importantes, considerando no solamente factores cuantitativos, sino también cualitativos.

La propuesta comprende dos etapas: (1) categorización (agrupamiento) de unidades consumidoras en grupos del mismo perfil de facturación y consumo de energía eléctrica, y (2) clasificación para identificar cuáles unidades consumidoras cambian de perfil en cada nueva medición realizada por la empresa. Esta metodología consideró las características históricas y estacionales de cada unidad consumidora (cliente).

El presente artículo está organizado de la siguiente manera: primero, se presenta la revisión de la literatura. Luego, se describe el método propuesto. A continuación, se presentan los resultados. Finalmente, se mencionan las conclusiones del trabajo.

REVISIÓN DE LITERATURA

Insolvencia en servicios públicos

Insolvencia, a rigor, es una situación de cualquier quiebra de cláusula de contrato. En el mercado financiero, sin embargo, muchas veces el término es usado como sinónimo de situación de atraso de deuda. Para una distribuidora, el insolvente es aquel cliente que dejó de pagar sus deudas (facturas de consumo de energía) al día.

La mayoría de las empresas sufre con los consumidores insolventes, siendo uno de los factores que más alcanza (impacta) a los sectores de comercio y de servicios, y hace que muchos empresarios se sientan desprotegidos. De ese modo, es importante cuestionarse ¿qué lleva a los consumidores a la insolvencia? A continuación, se indican algunos de los principales factores: Dificultades financieras (que imposibilitan el cumplimiento de obligaciones), falta de control en los gastos, atraso en recibir las facturas, renta comprometida en otras acreencias, baja en las ventas, uso del dinero en otras compras, mala fe.

Los diversos factores que deben ser tomados en cuenta en la gestión de la insolvencia de un portafolio de clientes no son totalmente previsibles. De esa forma, la toma de decisiones en este contexto es siempre una tarea compleja.

Para identificar las unidades consumidoras que presentan insolvencia, se ha utilizado técnicas computacionales clásicas de programación matemática y estadística (Guha, Rastogi, & Shim, 1998; R. A. Johnson & Wichern, 2002). Estas técnicas comúnmente aplicadas sobre el análisis de variación porcentual de consumo tienen aún resultados poco precisos. Las técnicas de inteligencia computacional (Berry & Linoff, 1997; Guha et al., 1998) se presentan como una alternativa viable para realizar un análisis amplio de todas las clases económicas presentes en la base de datos.

Este trabajo propone la categorización natural del espacio muestral de los clientes de la Light S.A. con el algoritmo Fuzzy C-means (Bezdek & Pal, 1994; Flores-Sintas, Cadenas, & Martin, 1999), en función de las características de consumo de energía eléctrica de estas unidades durante los meses de enero a diciembre. Independientemente de sus actividades económicas y considerando el comportamiento estacional de las facturas, la clasificación de los clientes en solventes e insolventes es realizada utilizando redes neuronales con aprendizaje del tipo Back-Propagation.

Técnica de agrupamiento: Fuzzy C-Means

El análisis de clúster es una técnica exploratoria de datos que tiene por objetivo formar grupos de objetos semejantes en una base de datos. El concepto de “clusterización” se diferencia del concepto de “cla-

sificación” en el hecho de que el análisis de clúster es una técnica más “primitiva”, en la cual ninguna suposición es hecha al respecto de los grupos, de su número y/o estructura (S. C. Johnson, 1967). Los clúster son obtenidos por intermedio de la aplicación de los conceptos de similitud y de distancia.

El algoritmo Fuzzy C-means (FCM), originalmente introducido por J. Bezdek en 1981 (Bezdek, 2013), es la versión fuzzy del método rígido k-means, siendo empleado para clasificar un universo de muestras en categorías fuzzy de acuerdo con la disposición en el espacio euclidiano.

En el agrupamiento no difuso, el límite de diferentes clústeres es fijo. Esto significa que cada patrón pertenece solamente a un único grupo. En el agrupamiento difuso, cada patrón no pertenece solamente a un único grupo, sino más bien a varios grupos con diferentes grados de pertenencia para cada grupo.

El algoritmo Fuzzy c-Means (FCM) es una variante del algoritmo Fuzzy Clustering iniciado por Bezdek al final de los años 70 (Hall, Ozyurt, & Bezdek, 1998). El algoritmo intenta agrupar las medidas a través de la búsqueda del mínimo local de la generalización de la suma de los cuadrados de los errores de las funciones.

El problema del agrupamiento difuso puede ser definido de la siguiente forma (Flores-Sintas et al., 1999; Hall et al., 1998; Lin & Lee, 1996):

Sea $X = \{x_1, x_2, \dots, x_n\}$ un conjunto de datos finito compuesto de elementos del Espacio Euclidiano dimensional R^p tal que, $x_j \in R^p, j=1, 2, \dots, n$. Se desea particionar los elementos en “c” conjuntos difusos de forma que se optimice una cierta función objetiva, donde “c” es el número de clusters.

El resultado del agrupamiento difuso puede ser expresado a través de la siguiente matriz U (1):

$$U = [u_{ij}] \quad i = 1, \dots, c \quad j = 1, \dots, n \quad (1)$$

Donde u_{ij} es un valor entre [0,1] que indica el grado de pertenencia de cada elemento x_j para un determinado i-ésimo cluster.

Trivedi y Bezdeck desarrollaron la siguiente función objetiva para el algoritmo FCM, (2):

$$J(u_{ij}, v_k) = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \|x_j - v_i\|^2, \quad 1 < m < \infty. \quad (2)$$

donde “m” es el coeficiente difuso responsable por el grado de “fuzzificación” de los elementos de la matriz U y “ v_k ” es el centroide del k-ésimo cluster.

Cuanto mayor es el coeficiente difuso “m”, más difusa se torna la matriz U. Cuando $m=1$, la función objetiva $J(u_{ij}, v_k)$ es reducida al caso crisp del algoritmo de agrupamiento k-means.

El objetivo es minimizar $J(u_{ij}, v_k)$, para lo cual basta diferenciar la función objetiva dada por (2) en relación a v_i (fijando $u_{ij}; i=1, \dots, c; j=1, \dots, n$), y en relación a u_{ij} (fijando $v_i; i=1, \dots, c$), de donde se obtiene (3) y (4):

$$v_i = \frac{1}{\sum_{j=1}^n (u_{ij})^m} \sum_{j=1}^n (u_{ij})^m x_j, \quad i=1, 2, \dots, c \quad (3)$$

$$u_{ij} = \frac{\left(\frac{1}{\|x_j - v_i\|^2} \right)^{1/m-1}}{\sum_{k=1}^c \left(\frac{1}{\|x_j - v_k\|^2} \right)^{1/m-1}} \quad (4)$$

$$i = 1, 2, \dots, c;$$

$$j = 1, 2, \dots, n.$$

Algoritmo FCM:

1. Escoger el número de clusters “c” ($2 \leq c \leq n$), el coeficiente Fuzzy “m” ($1 < m < \infty$), el criterio de parada ε , y la matriz inicial $U(0)$. Colocar el índice $l=0$.
2. Calcular el centro de los clusters $\{v_i^{(l)} \mid i=1,2,\dots,c\}$
3. Calcular la nueva matriz $U(l+1)$
4. Calcular $\Delta = \|U(l+1) - U(l)\| = \max_{i,j} |u_{ij}^{(l+1)} - u_{ij}^{(l)}|$ si $\Delta > \varepsilon$, entonces $l=l+1$ y retorna al paso 2. Si $\Delta \leq \varepsilon$ fin.

Técnicas de clasificación: Redes Neuronales Back Propagation

Las redes neuronales Back-Propagation (BP) (Haykin, 1994) son redes feed-forward de una o más capas ocultas. Este algoritmo define una manera sistemática de actualización de los pesos de las diversas capas, basada en la idea de que los errores de las neuronas de las capas ocultas son determinadas por la retro propagación reversa de los errores de las neuronas de la capa de salida.

El entrenamiento supervisado es basado en el método del gradiente decreciente (gradient descent), buscando minimizar el error global de la capa de salida. De este modo, la actualización del peso (Δw_{ij}) es proporcional al negativo de la derivada parcial del error con relación al propio peso (5):

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \quad (5)$$

Donde η es la tasa de aprendizaje y E es la función error definida como (6):

$$E = \frac{1}{2} \sum_{i=1}^{N_o} (t_j - s_j)^2 \quad (6)$$

Donde N_o es el número de procesadores (neuronas) de la capa de salida y t_j es el valor esperado en la salida del procesador j .

Derivando (5), se llega a la siguiente fórmula (7):

$$\Delta w_{ij} = \eta \cdot s_i \cdot e_j \quad (7)$$

$$e_j = \begin{cases} (t_j - s_j) f'(net_j) & \text{si } j \in \text{capa de salida} \\ f'(net_j) \sum_{k=1}^N w_{jk} e_k & \text{si } j \in \text{capa oculta} \end{cases}$$

Donde η es la tasa de aprendizaje; s_i es la entrada asociada al peso w_{ij} ; e_j es el error del j -ésimo procesador; t_j es el valor deseado de salida del procesador j ; s_j es su estado de activación; net_j es su potencial interno; f' es la derivada de la función de activación; y N es el número de procesadores en la capa siguiente a la capa del procesador j .

Como se puede verificar de la ecuación (7), el algoritmo de aprendizaje del Back Propagation tiene dos etapas para cada patrón presentado: Feed-Forward y Feed-Backward. En la primera etapa, las entradas se propagan por la red, de la capa de entrada hasta la capa de salida, generando la salida de la red en respuesta al patrón presentado. En la segunda etapa, los errores se propagan en la dirección contraria al flujo de datos, yendo de la capa de salida hasta la primera capa oculta, actualizando los pesos sinápticos. Este procedimiento de aprendizaje es repetido diversas veces, hasta que el error sea menor del que fue especificado para todos los procesadores de la capa de salida y para todos los patrones de entrenamiento.

Fue demostrado que el algoritmo Back Propagation es un aproximador universal (Hornik, Stinchcombe, & White, 1989), siendo capaz de aprender cualquier mapeo de entrada-salida. Sin embargo, a pesar del gran suceso del Back Propagation en sus diferentes aplicaciones, existen algunos problemas básicos: la definición del tamaño de la red, el largo proceso de entrenamiento, y fenómenos como la parálisis de la red (contornado disminuyendo el valor de η) y el mínimo local (que puede ser solucionado utilizando métodos estadísticos).

La definición del tamaño de la red, que es el número de capas ocultas y el número de procesadores en cada una de esas capas, es un compromiso entre la convergencia y la generalización. La convergencia es la capacidad de la red neuronal de aprender todos los patrones del conjunto de entrenamiento. Por otro lado, la generalización es la capacidad de responder correctamente a los patrones nunca vistos (conjunto de test). El objetivo es utilizar el menor número de redes posibles, de forma que se obtenga una buena generalización que sea capaz de aprender todos los patrones. La tasa de aprendizaje η es un parámetro importante a ser definido en el aprendizaje. Esta no debe ser ni muy pequeña, causando un entrenamiento muy lento; ni muy grande, generando oscilaciones. Cuando la tasa de aprendizaje es pequeña, y dependiendo de la inicialización de los pesos (hecha de forma aleatoria), la red neuronal puede quedar presa en un mínimo local. Cuando la tasa de aprendizaje es grande, la red neuronal puede nunca conseguir llegar al mínimo global, pues los valores de los pesos son grandes. La solución para este problema es utilizar una tasa de aprendizaje adaptativa. Además de este parámetro, se puede también utilizar un término α de momento (Haykin, 1994), proporcional a la variación del valor del peso sináptico en el paso anterior. De este modo, la ecuación de actualización del peso sináptico w_{ij} es modificada de la siguiente forma (8):

$$\Delta w_{ij}(t+1) = \eta \cdot s_i \cdot e_j + \alpha \Delta w_{ij}(t) \quad (8)$$

La utilización del término de momento tiene como función acelerar la convergencia de la red, sin causar oscilaciones.

MÉTODO

El modelo fue aplicado a partir de la división del problema en tres etapas: (1) el pre-procesamiento de datos de la empresa de distribución, (2) el agrupamiento de la base de datos histórica de facturación de los clientes utilizando técnicas estadísticas y el algoritmo Fuzzy C-means, y (3) la clasificación de los clientes insolventes según estos grupos.

El método en detalle se describe en la Figura 1.

La base de datos fue entregada por la empresa en un archivo texto, el cual contenía 51 campos relacionados a información de los clientes (p.e. Número de cliente, actividad, antigüedad como cliente). El Anexo 1 detalla los campos de esta base. Luego, se procedió a un proceso de validación. A la base validada se agregó un conjunto de índices económicos que afectan las actividades económicas de los clientes, como se aprecia en el Anexo 2.

Como resultado de este proceso, se obtuvo una base de datos capaz de ser tratada por los procesos de agrupamiento y clasificación.

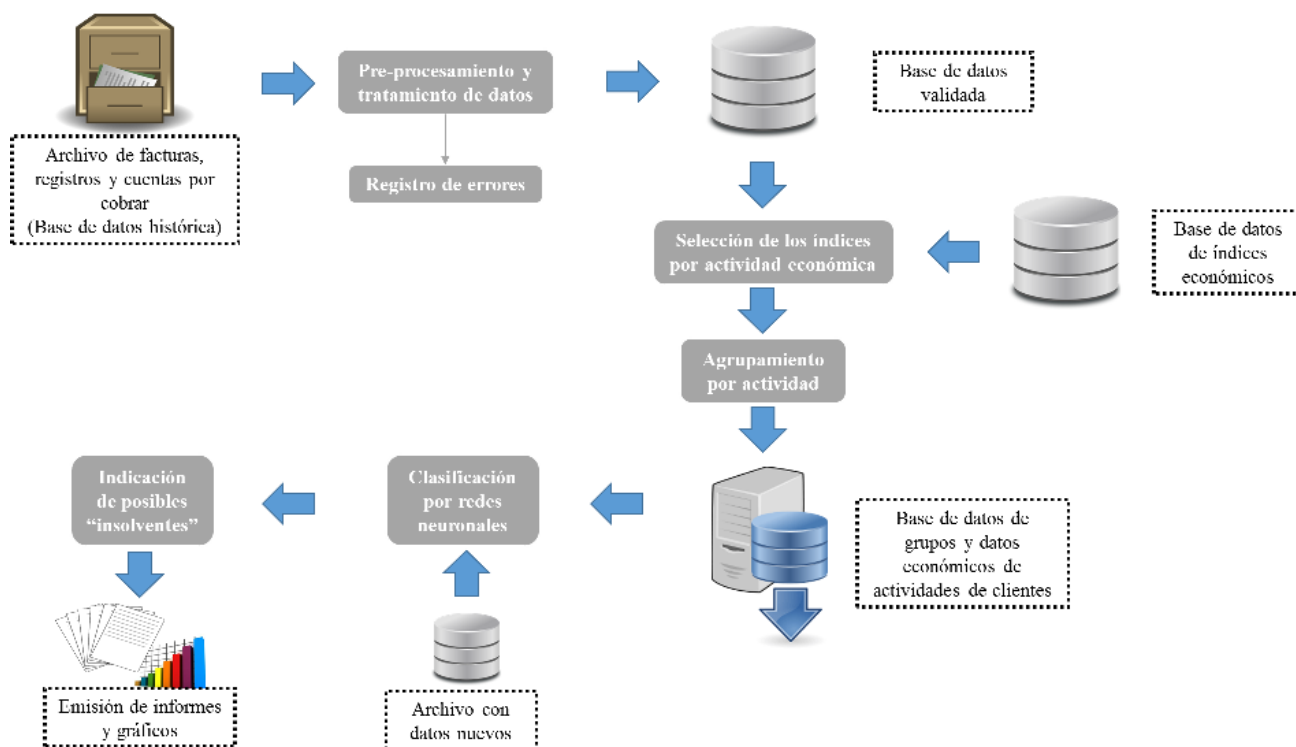


Figura 1. Método de trabajo

RESULTADOS

Del histórico de datos entregados por Light S.A, el volumen de clientes/facturas existentes en la base de datos necesitó agruparse. El criterio usado para agrupar fue la similitud entre las actividades (código CNAE), indicadores financieros, nivel de consumo, así como por el tipo de institución (municipal, estatal, o federal) de cada cliente definido en el sistema de la empresa.

De esa forma, se identificó 34 grupos de clientes/facturas, de los cuales 11 grupos correspondían a grandes clientes.

De los grupos de grandes clientes, los 8 primeros fueron definidos a partir del análisis estadístico de la base de datos y, por presentar una cantidad mayor de clientes/facturas en el período comprendido entre enero del 2006 a diciembre del 2011. Se verificó también que los clientes/facturas de cada una de estas actividades presenten entre sí una correlación significativa. Las pruebas comprobaron que cada una de las actividades constituyen naturalmente un grupo. Los tres grupos siguientes fueron obtenidos con el restante de clientes/facturas. Estos agrupamientos fueron realizados utilizando el algoritmo Fuzzy C-means considerando también la influencia de los índices económicos en la correlación al porcentaje de insolvencia. La Tabla 1 presenta estos 11 grupos.

Grupos Grandes Clientes	
1	Agua, desagüe, gestión de residuos y descontaminación.
2	Actividades adm. y servicios complementarios.
3	Educación.
4	Comercio; reparación vehículos automotores y motocicletas.
5	Comercio minorista de productos nuevos no especificados anteriormente y de productos usados.
6	Actividades financieras, seguros y relacionados.
7	Alojamiento.
8	Alimentación.
9	G1: Ind. extractivas, construcción, información y comunicación, financieras, seguros y serv. relacionados, artes, cultura, deporte y recreación.
10	G2: Ind. De transformación, electricidad y gas, transporte, almacenaje y correo, actividades profesionales, científicas y técnicas.
11	G3: Agricultura, pecuaria, producción forestal, pesca y acuicultura, actividades inmobiliarias, adm. pública, defensa y seguridad social, salud humana y servicios sociales, otras actividades de servicios.

Tabla 1.
Grupos para Clasificación de Grandes Clientes

Para cada uno de estos grupos fue modelada una red neuronal que tiene por función clasificar cada cliente en “solvente” o “insolvente”.

Para evaluar los resultados de la clasificación, Light S.A entregó para cada mes un conjunto de clientes insolventes. Así, se compara la lista de clientes insolventes real con la lista de clientes entregada por el sistema después de la clasificación. De esta forma, es posible calcular los errores de clasificación para cada grupo de clientes.

Las redes neuronales fueron modeladas considerando las siguientes entradas:

- Código Tipo de Tarifa;
- Valor de Emisión de la factura;
- Meses como Clientes de Light S.A;
- Código de la Localidad;
- Diferencia de pago vencimiento anterior;
- Insolvencia de Largo Plazo Anterior; y
- Número de Insolvencias Anteriores.

Como salida de estas redes neuronales se consideró:

- Insolvente o no en esta factura.

El código de la localidad en las pruebas fue representado de forma binaria o real, dependiendo del grupo. Por otro lado, como el número de clientes/facturas insolventes en todos los grupos es menor que el número de clientes/facturas solventes, es necesario aplicar técnicas de balanceo de los datos para mejorar el desempeño de la red neuronal. De esa forma, se podrá tener el mismo número de muestras de solventes e insolventes sin pérdida de información.

La técnica de balanceo de datos usada fue la de re-muestreo (o réplica) de datos de los insolventes, aumentando así la cantidad de muestras de insolventes hasta alcanzar el mismo número de muestras de clientes/facturas solventes.

Fueron realizados diversas pruebas con redes neuronales variando el número de neuronas de la capa oculta para identificar la mejor topología. También fueron realizadas las pruebas para estas diferentes tipologías con varios conjuntos de muestras de datos.

A continuación, en la Tabla 2 y Tabla 3 se muestran los resultados obtenidos para los grupos de grandes clientes y clientes del sector público, con los errores porcentuales de la clasificación en el entrenamiento y prueba.

Grupos Grandes Clientes	Error Grupo Entrenamiento %	Error Grupo Prueba %
1	13,53	14,36
2	14,47	10,46
3	24,73	10,47
4	18,62	9,65
5	14,32	11,46
6	8,04	15,31
7	15,22	10,42
8	17,03	15,69
9	24,39	12,72
10	15,76	18,30
11	20,52	11,03

Tabla 2.
Grupos para Clasificación de grandes Clientes

CONCLUSIONES

Este artículo presentó el desarrollo de un método para la identificación de la insolvencia en la facturación de energía eléctrica para grandes clientes.

Los resultados obtenidos con el sistema evidenciaron la capacidad del sistema en detectar clientes insolventes, con errores de clasificación bastante aceptables, considerando que no es posible para una distribuidora de energía conseguir y analizar los datos financieros de todos sus clientes. Estos resultados fueron verificados y confirmados por los datos históricos de la empresa Light S.A.

Agradecimientos: Los autores agradecen a la distribuidora de energía de Rio de Janeiro, Light Serviços de Eletricidade S.A., por el apoyo en proporcionarnos la información para la realización de este trabajo.

REFERENCIAS

- Anagnostopoulos, Y., & Abedi, M. (2016). Risk Pricing in Emerging Economies: Credit Scoring and Private Banking in Iran. *International Journal of Finance & Banking Studies (2147-4486)*, 5(1), 51-72.
- Berry, M. J., & Linoff, G. (1997). *Data mining techniques: for marketing, sales, and customer support*: John Wiley & Sons, Inc.
- Bezdek, J. C. (2013). *Pattern recognition with fuzzy objective function algorithms*: Springer Science & Business Media.
- Bezdek, J. C., & Pal, S. K. (1994). Fuzzy models for pattern recognition: USDOE Pittsburgh Energy Technology Center, PA (United States); Oregon State Univ., Corvallis, OR (United States). Dept. of Computer Science; Naval Research Lab., Washington, DC (United States); Electric Power Research Inst., Palo Alto, CA (United States); Bureau of Mines, Washington, DC (United States).
- Doumpos, M., & Zopounidis, C. (2014). Credit Scoring *Multicriteria Analysis in Finance* (pp. 43-59): Springer.
- Flores-Sintas, A., Cadenas, J., & Martin, F. (1999). Membership functions in the fuzzy C-means algorithm. *Fuzzy Sets and Systems*, 101(1), 49-58.
- Guha, S., Rastogi, R., & Shim, K. (1998). *CURE: an efficient clustering algorithm for large databases*. Paper presented at the ACM Sigmod Record.
- Hall, L., Ozyurt, B., & Bezdek, J. (1998). *The case for genetic algorithms in fuzzy clustering*. Paper presented at the Traitement d'information et gestion d'incertitudes dans les systèmes à base de connaissances. Conférence internationale.
- Haykin, S. (1994). *Neural networks: A comprehensive foundation*: Macmillan College Publishing Company.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359-366.
- Johnson, R. A., & Wichern, D. W. (2002). *Applied multivariate statistical analysis* (Vol. 5): Prentice hall Upper Saddle River, NJ.
- Johnson, S. C. (1967). Hierarchical clustering schemes. *Psychometrika*, 32(3), 241-254.
- Lin, C.-T., & Lee, C. (1996). *Neural fuzzy systems: a neuro-fuzzy synergism to intelligent systems*: Prentice-Hall, Inc.

ANEXOS

Anexo 1.

Atributos del archivo de la base de datos de los clientes

	Campo - Descripción
1	CNAE
2	Actividad
3	Número de la Factura
4	Número de Documento
5	Instalación (UC)
6	Código Tipo de Tarifa (formato real)
7	Código Tipo de Tarifa (formato binario)
8	Valor de Emisión
9	Meses que es Cliente Light
10	Código Localidad
11	Código Situación Factura
12	Diferencia Pago y Vencimiento
13	Insolvencia
14	Insolvencia de Largo Plazo
15	Cantidad Consumo
16	Consumo Punta
17	Consumo Fuera Punta
18	Valor Consumo
19	Valor Consumo Punta
20	Valor Consumo Fuera Punta
21	Demanda Contratada
22	Demanda Contratada Punta
23	Demanda Contratada Fuera Punta
24	Demanda Registrada
25	Demanda Registrada Punta
26	Demanda Registrada Fuera Punta
27	Demanda Ultrapasaje
28	Demanda Ultrapasaje Punta
29	Demanda Ultrapasaje Fuera Punta
30	Demanda Facturada
31	Demanda Facturada Punta
32	Demanda Facturada Fuera Punta
33	Demanda Reactiva
34	Demanda Reactiva Punta
35	Demanda Reactiva Fuera Punta
36	Valor Demanda
37	Valor Demanda Punta
38	Valor Demanda Fuera Punta
39	Valor Demanda Ultrapasaje

40	Valor Demanda Ultrapasaje Punta
41	Valor Demanda Ultrapasaje Fuera Punta
42	Consumo Reactivo
43	Consumo Reactivo Punta
44	Consumo Reactivo Fuera Punta
45	Valor Consumo Reactivo
46	Valor Consumo Reactivo Punta
47	Valor Consumo Reactivo Fuera Punta
48	Valor Demanda Reactiva
49	Valor Demanda Reactiva Punta
50	Valor Demanda Reactiva Fuera Punta
51	Número Insolvencias Anteriores

Anexo 2.

Índices económicos

	Campo	Descripción
1	Fecha	Fecha relativa al mes del índice
2	Índice 1	Industria extractiva - RJ
3	Índice 2	Industria generalv- RJ
4	Índice 3	Industria de transformación - RJ
5	Índice 4	Alimentos - RJ
6	Índice 5	Bebidas - RJ
7	Índice 6	Textil - RJ
8	Índice 7	Edición, Impresiones y producción de grabaciones - RJ
9	Índice 8	Refinería de petróleo y alcohol - RJ
10	Índice 9	Farmacéutica - RJ
11	Índice 10	Perfumería, Jabones, Detergentes y Prod. de limpieza - RJ
12	Índice 11	Otros productos químicos - RJ
13	Índice 12	Caucho y plástico - RJ
14	Índice 13	Minerales no metálicos - RJ
15	Índice 14	Metalurgia básica - RJ
16	Índice 15	Vehículos automotores - RJ
17	Índice 16	Taza de cambio (R\$/US\$) promedio mensual compra
18	Índice 17	Ibovespa - Promedio mensual
19	Índice 18	Vestuario y accesorios - RJ
20	Índice 19	Nominal ventas minoristas - RJ
21	Índice 20	Nominal ventas minoristas (combust. y lubrif.) - RJ
22	Índice 21	Nominal ventas minoristas (Hip. Sup. Prod. Alim., beb., tabaco) - RJ
23	Índice 22	Nominal ventas minoristas (Tej., Vest. y Calzado) - RJ
24	Índice 23	Nominal ventas minoristas (Muebles y electrodomesticos) - RJ
25	Índice 24	Nominal ventas minoristas (Hipermercados y supermercados) - RJ
26	Índice 25	Nominal ventas minoristas (Vehículos, motos, partes y piezas) - RJ
27	Índice 26	Maq. Para escritorio e Equipo de informática - RJ
28	Índice 27	Máquinas y equipos - RJ
29	Índice 28	Celulosa, papel y prod, de papel - RJ
30	Índice 29	Calzados y artículos de cuero - RJ