



Picco, Alicia M.

Marchese, Alicia G.

Pluss, Jorge J.

Gaibazzi, María F.

Repetto, Luciano

Instituto de Investigaciones y Asistencia Tecnológica en Administración, Escuela de Administración.

SISTEMAS DE CONOCIMIENTO PARA EL ANÁLISIS FINANCIERO

Introducción

Hace algunos años comenzamos nuestra investigación acerca de las posibles aplicaciones de Sistemas de Conocimiento al Análisis Financiero y la Contabilidad. Desde la integración de un conjunto de reglas para formular un Sistema Experto hasta la visualización de las diversas tecnologías existentes que pudieran aportar nuevos elementos, hemos adquirido diversas experiencias que, entendemos, merecen ser difundidas. En el transcurso del mismo hemos estudiado Algoritmos Genéticos, Redes Neuronales y propuesto la creación y desarrollo de almacenes de datos para su análisis a través de Datamining o Minería de Datos.

Es sabido que en la actualidad las Tecnologías de Conocimiento se encuentran ampliamente difundidas en los ámbitos internacionales, y resulta innegable que nuestros empresarios locales deben incorporarlas para poder interactuar con entidades financieras y gubernamentales y, fundamentalmente, para "apalancar" su propio desarrollo.

En este trabajo abordaremos la aplicación de sistemas que aportan conocimiento al análisis financiero. La problemática se tratará desde puntos de vista complementarios: el primero será la mención de los conceptos teóricos involucrados, para luego analizar casos internacionales de entidades financieras y organismos gubernamentales que los aplican. Luego expondremos nuestra experiencia en el desarrollo de una aplicación destinada a empresas, que diagnostica su situación



financiera y favorece la obtención de financiamiento externo. Nuestra intención es realizar una reseña de las aplicaciones más relevantes, partiendo de los conceptos teóricos involucrados, para concluir con la experiencia adquirida en el desarrollo de un producto de análisis financiero.

Aprendizaje en las Redes Neuronales

Básicamente, las redes neuronales aprenden relacionando los datos a través de las ponderaciones que se les den a estos y que luego irán modificando hasta llegar a un nivel de relación óptimo, es decir, cuando se encuentren los "pesos" correctos para los datos.

Para la corrección de los pesos de los datos, existen tres métodos:

Supervisado:

En este método, cuando le presentamos a la red los datos de entrada para que genere una salida, se tiene la salida óptima, por lo cual, si existe una diferencia, se aplica la regla Delta, que es la disminución progresiva del error, modificando los pesos.

No Supervisado:

La red sólo cuenta con los datos de entrada y los irá clasificando en categorías según las características distintivas de ellos. Entonces se les aplican diversas reglas de aprendizaje, en la cual se destacan las reglas de Hebb, *donde las neuronas que se conecten con mayor fuerza, van a obtener mayor peso dentro de la red*; y las reglas de aprendizaje competitivo, *donde los pesos son modificados en función del ingreso o no de patrones cuyas características puedan ser reconocidas por la red.*¹

Autosupervisada:

Es una forma similar al Aprendizaje supervisado pero en el cual se le indica a la red que la salida generada es incorrecta pero no se le especifica en cuánto varía su salida de la salida esperada u óptima. Este es el primer método² en el cual se centra éste trabajo.

Un ejemplo del método supervisado con *regla delta* puede ser el siguiente:

¹; Iovaldi, Raúl, "Inteligencia Artificial y Aprendizaje", Ed. UNR, Rosario, 2001



Dado que necesitamos una salida óptima, se hará referencia a las reglas de la Base del Conocimiento del Sistema Experto en Diagnóstico y Asesoramiento Financiero (SEDAF), a cuya implantación nos referimos más adelante.

"Si tengo una liquidez directa de 1,5 y una liquidez corriente de 2,5, por lo tanto, la liquidez general es "3" (etiqueta que equivale a la calificación de bueno)."

Aplicada una simple neurona, tendremos:

$$X1 = 1,5; X2 = 2,5; SD = 3$$

$$\sum_{i=1}^n W_i \cdot X_i$$

Y para este caso se ha elegido como función de base a $f/f(x) = \sum_{i=1}^n W_i \cdot X_i$, y como función de activación a $g/g(x) = [f(x)]$, es decir, la parte entera de $f(x)$.

En una simple tabla de Excel, podemos ver paso a paso como se va calculando la salida y la modificación de los pesos:

Tabla nº1: Aprendizaje por regla Delta

Etapa I					
Datos	Ponderación	Función de	Función de	Salida	Diferencia
Coeficientes	nº1	Base	Activación	Esperada	
1,5	0,5	5,75	5	3	-2
2,5	2				
Etapa II					
	Nueva Ponderación	Función de Base	Función de Activación	Salida Esperada	Diferencia
	0,2	4,05	4	3	-1
	1,5				
Etapa III					
	Nueva Ponderación	Función de Base	Función de Activación	Salida Esperada	Diferencia
	0,05	3,2	3	3	0
	1,25				

En el 1er. Intento, llamado *Época* o *Ciclo de Aprendizaje*, la neurona obtuvo una salida distinta la a óptima / deseada, y a tal diferencia la llamamos Error

² Conociendo que las redes neuronales con los otros métodos de aprendizaje pueden tener mejores



Para actualizar los pesos (W_i), lo que se trata de hacer es asignar una porción de dicho error a cada uno de ellos, junto con una constante llamada **razón de aprendizaje**, condiciiona a los Ciclos o Épocas en que debe aprender la neurona. Es por ello que se busca la variación y se la aplica a cada peso "incorrecto", es decir:

$$\Delta W_i = (\lambda - o_i) \cdot \alpha \cdot X_i \quad \text{donde}$$

λ Es la salida Esperada
 o_i Es la salida calculada
 α Es la razón de aprendizaje

el nuevo peso será: $\Delta W_i + W_i = W_i$

En nuestro ejemplo:

{ $3 - [0,5 * 1,5 + 2 * 2,5] * 0,2 * 1,5$ } para el caso de corregir 0,5 y

{ $3 - [0,5 * 1,5 + 2 * 2,5] * 0,2 * 2,5$ } para el peso 2,

repetiéndose hasta que la diferencia es igual a cero³.

¿Cuántos "pesos" son capaces de relacionar la liquidez directa y corriente con la liquidez general?

El aprendizaje de las neuronas establece, en cualquier método, que el Error es en función de las ponderaciones de los datos a relacionar. De ahí podemos expresar⁴ (sin mayor rigurosidad) que:

$$E(w_i) = \lambda - g[f(x)]$$
$$E(w_i) = \lambda - g\left[\sum_{i=1}^n X_i \cdot W_i\right]^5$$

resultados, sin embargo, nuestro objetivo es entender la filosofía de la redes neuronales

³ Se calculó la variación de W_i , no el nuevo valor de W_i

⁴ siempre estamos trabajando con el ejemplo que dimos anteriormente, se opera con una función entero de x

⁵ recordemos, que el segundo restando es igual a la salida calculada por la neurona



Representado esta relación en los ejes x , y , z , donde los valores para W_1 estén sobre el eje de las y , los valores de W_2 sobre el eje de las x y los valores de $E_{(w_1, w_2)}$ sobre el eje de las z , tendremos un plano de ecuación:

$$E_{(w_1, w_2)} = \lambda - [X_1 \cdot W_1 + X_2 \cdot W_2]$$

donde se encuentran todos los pesos que definen a $E_{(w_1, w_2)}$, como se quiere encontrar el caso en que $E_{(w_1, w_2)} = 0$, que significa que los pesos son los correctos y el aprendizaje a terminado, tenemos:

$$E_{(w_1, w_2)} = \lambda - [X_1 \cdot W_1 + X_2 \cdot W_2] = 0$$

hacemos pasaje de

términos,

$$[X_1 \cdot W_1 + X_2 \cdot W_2] = \lambda$$

teniendo en cuenta que operamos con una función $g/g(x) = [x]$, $\lambda \in \mathbf{N}$ y la suma da como resultado un nro. $\in \mathbf{N}$, se expresa,

$$X_1 \cdot W_1 + X_2 \cdot W_2 = \lambda$$

}	λ	Es la distancia proporcional al origen de coordenadas.
	$\vec{n} = (x_1, x_2)$	El vector normal a dicho plano

Reemplazando con los datos del ejemplo:



$$1,5W_1 + 2,5W_2 = 3 \quad ^6$$

Todos los puntos que pertenezcan a ésta última plano, proyectante sobre el plano de coordenadas (XY), serán los pesos correctos para el fin del aprendizaje de neurona del ejemplo, pudiéndose con el mismo razonamiento, explicar para otra función de activación distinta a la dada, sujeto a las distintas particularidades de cada una.

Sin embargo las limitaciones de una neurona son grandes, por lo que se necesita adicionarle una estructura.


Este paso le agrega tanto eficiencia como complejidad. Cuando tenemos una red neuronal multicapa, el problema de la modificación de pesos se acrecienta. Pues no solo hay que modificar la ponderación de la neurona de salida, sino las neuronas ocultas y las neuronas de entrada.

Muchos años pasaron para poder encontrar una solución para este inconveniente, hasta que a finales de la década del '80 se desarrollo el **algoritmo Back-Propagation**, que permite *propagar* el error hasta el inicio del calculo neuronal, hasta las neuronas de entrada.

Llamemos *i* a la capa de neuronas de salida, *j* a la capa de neuronas ocultas y *k* a la capa de neuronas de inicio.

Figura nº1: Red neuronal multicapa

⁶ siendo $n = (1,5;2,5)$ el vector normal al plano



Para la primera capa –de salida- la modificación es igual a la anterior, con dos diferencias; los valores de entrada serán los de a_j , es decir los valores de salida que nos proporciona la capa oculta, y la derivada de la función $g'[f(x)_i]$, nos indica la inclinación de que debe tener $g(x)$.

$$W_{j,i} = W_{j,i} + \alpha \cdot a_j \cdot \text{Err}_i \cdot g'[f(x)_i] \quad 7$$

donde se puede definir la variación $\Delta_i = \text{Err}_i \cdot g'[f(x)_i]$, que es error que debe "pasar hacia atrás" la neurona i .

$$W_{j,i} = W_{j,i} + \alpha \cdot a_j \cdot \Delta_i$$

como las neuronas k son responsables también del error, se les debe asignarlo, es decir, se debe distribuir Δ_i entre las neuronas de la capa de entrada, teniendo una nueva variación Δ_j , siendo entonces el error que va de j a k .

$$\Delta_j = g'[f(x)_j] \sum W_{j,i} \cdot \Delta_i$$

entonces,

⁷ $W_{j,i}$, son los pesos que conectan la capa de neuronas ocultas j con la capa de neuronas de salida i



$$W_{k,j} = W_{k,j} + \alpha \cdot I_k \cdot \Delta_j$$

donde I_k son los valores de entrada.

No se ha puesto un ejemplo de clasificación porque lo que interesaba era el poder de relación con que cuentan las redes neuronales en el momento de tener que "relacionar" datos, en miras de comprender su funcionamiento en los productos llamados Datamining, el cual su función más apreciada, en síntesis, extraer de una gran base de datos conclusiones para la toma de decisiones.

Datamining como herramienta para el análisis de datos

El descubrimiento de conocimiento en bases de datos (KDD Knowledge Discovery in Databases) desde su nacimiento ha estado íntimamente relacionado con el desarrollo de otro concepto importante, el Datawarehousing o almacenes de datos. La información en el Datawarehousing es orientada al sujeto, no volátil y de naturaleza histórica, por lo que los almacenes de datos tienden a contener una extrema cantidad de datos. La combinación de los almacenes de datos como soporte de las decisiones gerenciales, y Datamining muestran un innovador y revolucionario enfoque de la administración de información.

Concretamente podríamos decir que el datamining se define como la automatización o semi-automatización del descubrimiento de información, descriptiva o predictiva, oculta en grandes bases de datos. Otras definiciones dicen que datamining es el descubrimiento de información relevante implícita, previamente desconocida y potencialmente útil de los datos.

El Datamining se constituye en el complemento ideal de los almacenes de datos dada la capacidad limitada de las personas de procesar información. En el futuro, la habilidad para leer e interpretar por si solo no va ser suficiente para sobrevivir en el ambiente profesional ya sea para organizaciones científicas como comerciales. La producción mecánica y reproducción de datos nos fuerza a adaptar nuestras estrategias y desarrollar métodos mecánicos para filtrar, seleccionar e interpretar los datos.



Datamining versus las herramientas de consulta

¿Cual es la diferencia entre datamining y las herramientas de consulta? ¿Qué puede hacer el datamining que las herramientas de consulta como SQL no puede?

Lo primero que hay que decir es que el datamining y las herramientas de consulta son complementarias. Datamining no reemplaza las herramientas de consulta tradicionales, sino que solo le brinda posibilidades adicionales.

Supongamos que tenemos una base de datos conteniendo miles de registros que describan las compras de nuestros clientes en los últimos diez años. Esto es una gran cantidad de potencial conocimiento, la mayoría del cual puede ser descubierto a partir de las herramientas normales de consulta como el SQL, preguntas como ¿que producto fue comprado en que fecha? o ¿cuál es el promedio en el volumen de ventas en determinada fecha en un región determinada?.

Igualmente existe cierto conocimiento que es mucho más difícil extraer usando SQL, por ejemplo ¿cuál es la forma óptima de segmentar a mis clientes? o ¿cuál son las más importantes tendencias en el comportamiento de mis clientes?.

Si bien estas cuestiones se podría tratar de resolver a través de la concatenación de consultas SQL, previamente se debería definir un criterio de perfil de cliente y ejecutar una búsqueda y ver si funciona o no, en un proceso de prueba y error. Esto podría demorar días o meses para encontrar una segmentación óptima de una gran base de datos. Con la utilización de herramientas de Datamining se podría encontrar el resultado a esto de una manera mecánica y en mucho menos tiempo.

Uno podría decir que si se sabe exactamente qué se está buscando se debe utilizar SQL, pero si sólo se sabe vagamente qué se está buscando entonces hay que cambiar a datamining.

Esta claro que el KDD (Knowledge Discovery in Databases) no es una actividad que se establece por sí sola, sino que por ejemplo el datawarehouse es una condición necesaria para su implementación. Implementar KDD en una organización es comenzar un proceso permanente de refinación y detalle de los datos, con el objetivo último y real, que debería ser el de crear una organización que aprenda por si sola.



Proceso de generación del conocimiento

En este apartado vamos a analizar el proceso de descubrimiento de información a través de la discusión de las diferentes etapas del proceso.

- Selección de datos
- Depuración
- Enriquecimiento
- Datamining
- Reportes

La quinta etapa, datamining, es la verdadera etapa de descubrimiento. A pesar de que esta metodología es presentada como lineal, esto no es así, ya que el "minero de datos" puede ir hacia delante o atrás en cualquiera de las etapas del proceso. Por ejemplo, es imposible saber de antemano toda la contaminación que puede tener una base de datos, la mayoría de la cual es recién descubierta en la etapa de datamining.

Las organizaciones deberían trabajar continuamente sobre sus datos, identificando continuamente nuevas necesidades de información y mejorando sus datos para lograr de una manera cada vez más eficiente sus objetivos.

Analicemos ahora con algo más de profundidad las distintas etapas en el proceso de descubrimiento de conocimiento.

Selección de datos

Esta etapa se refiere exclusivamente al hecho de seleccionar los datos que van a ser analizados. En orden a facilitar el proceso de KDD se recomienda seleccionar adecuadamente los datos a analizar y copiarlos en una base de datos separada a la operacional.

Es importante recordar que en el método de KDD se produce el vieja regla de que "si entra basura, va a salir basura".

Depuración

Existen muchos procesos de depuración, muchos de los cuales pueden ser ejecutados durante el desarrollo de otras etapas, o son llamados cuando se detecta contaminación en los procesos de codificación o de descubrimiento.



Un elemento importante en la depuración de los datos es el de eliminar la duplicación de los registros, cuestiones muy comunes en las bases de datos. Estas duplicaciones pueden producirse por distintos errores como pueden ser el mal tipeo de los datos, negligencia de los empleados o acciones deliberadas, entre otras. Por supuesto es muy importantes que las compañías estén alertas sobre estas anomalías en sus bases de datos.

A pesar de que el datamining y la depuración de datos son dos disciplinas diferentes tienen mucho en común, y los algoritmos de reconocimiento de patrones pueden ser aplicados a la depuración de datos.

Enriquecimiento

Esto supone la incorporación o directamente compra de información adicional a la disponible en la base de datos. Por ejemplo si nosotros nos dispusiéramos a analizar la base de datos de distribución de una editorial, que publica tres tipos de revistas, sobre autos, música y deportes. Podría resultar interesante incorporar dentro de los datos que disponemos cuales de nuestros clientes son propietarios de sus casas o tienen auto, cual es su ingreso anual, o agregarle datos demográficos.

Codificación

En esta etapa primero es incorporada la información que se ha adquirido a cada uno de los registros de nuestra base de datos.

En un segundo paso seleccionamos solo aquellos registros que tienen información que pueda ser de valor. A pesar de que esto puede resultar muy difícil de reglar esta operación, esta situación se ve mejor frecuentemente en la práctica.

Una regla general es que cualquier eliminación de datos debe estar basada en una decisión consciente, previo paso por el análisis de las posibles consecuencias. Vale aclarar que en algunos casos la detección de algunos fraudes o faltas de información puede valuar indicadores de importantes patrones de comportamiento.

En este punto, la etapa de codificación solo ha consistido en nada más que simples operaciones con SQL, pero ahora comienza la etapa en donde debemos ser capaces de realizar transformaciones más creativas sobre nuestros datos. En este



punto la información en nuestras bases de datos es muy detallada como para servir como ingreso de un algoritmo de reconocimiento de patrones. Tomemos por ejemplo un dato como podría ser la fecha de nacimiento de nuestros clientes, un algoritmo que ordene a las personas que tengan la misma fecha de nacimiento seguramente resultará en un patrón extremadamente detallado para nuestros propósitos, mientras que, por ejemplo, realizando patrones por edad de con un rango de 10 años podría ser muy aplicable. Otro ejemplo podría ser el caso de las direcciones del domicilio, en vez de tomarlas por separado, agruparlas por códigos postales.

Una vez que se tienen los datos ordenados de esta forma, es una buena base por donde comenzar el proceso real de datamining.

Datamining

Datamining al contrario de cómo se podría pensar es un conjunto de técnicas que se utilizan para descubrir el conocimiento oculto en la superficie. Cualquier técnica que permita extraer algo de información adicional es útil, esto hace que las técnicas de datamining sean muy heterogéneas entre sí, para lo cual muchas de las técnicas son utilizadas para diferentes propósitos.

Actualmente las herramientas que utiliza el datamining son:

- Herramientas de consulta y técnicas estadísticas: este siempre debería ser el primer escalón en un proyecto de datamining, ya que a través de la utilización de herramientas tradicionales de consulta como SQL se puede obtener una información muy abundante. Si bien como ya dijimos anteriormente con SQL se obtiene la información que no se encuentra demasiado profunda, esto equivale aproximadamente al 80% de toda la información, para tener acceso al 20% restante es necesario utilizar otro tipo de técnicas. Una buena forma de empezar es extraer algo de simple información estadística, como promedios y desvíos estándar y otras medidas estadísticas.
- Visualización: las técnicas de visualización son un método muy útil para descubrir patrones en los conjuntos de datos y muchos son utilizados al principio del proceso de datamining para tener una idea



acerca de la calidad de los datos y de los patrones que se pueden descubrir.

- OLAP (On-line Analytical Processing / Procesamiento Analítico en línea)
- Aprendizaje basado en casos (case-based learning, k-nearest neighbor)
- Árboles de decisión
- Reglas de asociación
- Redes neuronales
- Algoritmos genéticos

Reportes

Una de las más importantes ventajas de este tipo de tecnología consiste en la facilidad con que se obtienen reportes sumamente amigables. El entorno gráfico y la posibilidad de "perforar" (drill down, o acceso a detalles mediante un simple click) o "agregar" (drill up, o agregación). Esto permite a usuarios no calificados manipular información y conocimiento con relativa facilidad contribuyendo a la más eficiente visualización para la toma de decisiones.

Los Servicios Financieros y el Data Warehousing

Las compañías financieras ya se aventuraban por el territorio del Data Warehousing antes de que el término hubiera sido siquiera acuñado, invirtiendo en grandes plataformas de base de datos para albergar datos detallados de transacciones.

En 1996, el Gartner Group encuestó a 144 instituciones financieras y descubrió que sus metas en servicio al cliente y efectividad de marketing, junto con la reducción de costos y la efectividad operacional, justificaban el Data Warehousing⁸. Sin embargo, y a pesar de la amplia aceptación de las tecnologías de DW, los bancos todavía

⁸ Presentación del Gartner Group "Breakthrough Banking Applications", enviada al seminario Profitable Data Warehousing Strategies for Financial Institutions, Atlanta, Georgia, 12 al 13 de febrero de 1996.



estaban claramente a mitad de camino entre la reducción de costos y la creación de valor.

Ahora Internet está calentando aún más el ambiente al permitir a nuevos jugadores ingresar en el mercado sin tener la carga de sucursales existentes e infraestructuras obsoletas.

Las compañías de servicios financieros están concentrando en optimizar la retención de clientes mediante la combinación de programas originales de marketing con servicios mejorados.

En los últimos años, la mayoría de los bancos adoptaron la noción de "Banca Minorista", que aplica al mundo de la banca minorista algunos de los conceptos del comercio minorista. Los Bancos están afinando sus habilidades en sus clientes consumidores, el segmento en el cual el volumen de clientes y las ventas de producto óptimas pueden dar como resultado ganancias significativas.

Para los bancos, la inteligencia comercial se ha vuelto no solamente un arma competitiva, sino también un mandato comercial. Los organismos reguladores como el BCRA han caído con todo su peso sobre las instituciones financieras, y las nuevas reglas como por ejemplo, la de "conoce a tu cliente" establecen que las instituciones financieras pueden discernir quién es quién de entre sus clientes a fin de calificarlos para los productos apropiados y potencialmente evitar fraudes.

Las firmas de servicios financieros están combinando detalles de transacciones – originados en cajeros automáticos, sitios Web, y transacciones por cajero – información de los productos, y datos acerca de los clientes y la historia de sus cuentas para realizar análisis de rentabilidad.

La rentabilidad del cliente es la forma más codiciada de información sobre rentabilidad por una muy buena razón: una compañía no puede saber el verdadero valor de un cliente sin una comprensión de su rentabilidad. Y si no conoce el valor de un cliente, el banco está forzado a adivinar el modo de tratarlo.

La combinación de diferentes tipos de rentabilidad puede ayudar a una firma de servicios financieros a tomar decisiones informadas sobre cómo tratar a sus clientes.



Gestión de riesgo y prevención de fraude

Un Data Warehouse le brinda a una compañía bancaria un enfoque científico de la gestión de riesgo (risk management), a diferencia del juego de adivinanzas que tradicionalmente ha estado asociado a la aprobación de créditos.

La gestión de riesgo puede individualizar mercados o segmentos de clientes específicos que pueden ser de mayor riesgo que otros, y a un nivel más detallado puede determinar los factores de riesgo de individuos específicos. Hay varias herramientas de software especializadas que ayudan a las firmas a realizar gestión de riesgo. La mayoría de ellas asignan un puntaje a un cliente o a un segmento, calibrando su riesgo en relación con el de otros clientes o segmentos. Algunas herramientas de verificación de fraude realizan una auténtica verificación de identidad, al calificar la historia personal y crediticia de un cliente para descubrir si es quien dice ser. El solo hecho de poder reducir la cantidad de deudas incobrables, evitar ejecuciones, y abstenerse de otorgar créditos a personas ficticias podría ahorrarle a algunos bancos pérdidas por créditos incobrables.

Los tipos más avanzados de gestión de riesgo y detección de fraude permiten la reevaluación continua del comportamiento del cliente.

Proceso de Gestión de Riesgo:

Pasos

- 1: El cliente solicita un préstamo.
- 2: El banco carga la solicitud de préstamo en el Datawarehouse.
- 3: La herramienta de gestión de riesgo evalúa los datos ingresados en la solicitud y produce un puntaje
- 4: Se comparan los datos y el puntaje con datos similares en el D W
- 5: La herramienta mide los datos resultantes de acuerdo a modelos de riesgo ya existentes.



Riesgo Crediticio

Procedimiento a tener en cuenta por la entidad financiera para autorizar o no el otorgamiento de un préstamo.

Conceptos a tener en cuenta:

Responsabilidad Patrimonial Computable

$$RPC = PNb + PNc - Cd$$

Patrimonio Neto básico:

- Capital social
- Aportes no capitalizados
- Ajustes al patrimonio
- Reservas de utilidades
- Resultados no asignados
- El resultado positivo del último ejercicio cerrado se computará una vez que se cuente con dictamen del auditor.
- En caso de consolidación incluye participación de terceros.

Patrimonio Neto complementario

- Resultado Negativo: Se toma el 100 % independientemente de que se cuente con informe o dictamen de Auditor.
- Resultado Positivo:

100 % de los EECC trimestrales con informe de Auditor

100 % de los EECC anual con dictamen de Auditor

50 % desde el último informe / dictamen del auditor de los EECC trimestrales / anuales

Conceptos deducibles

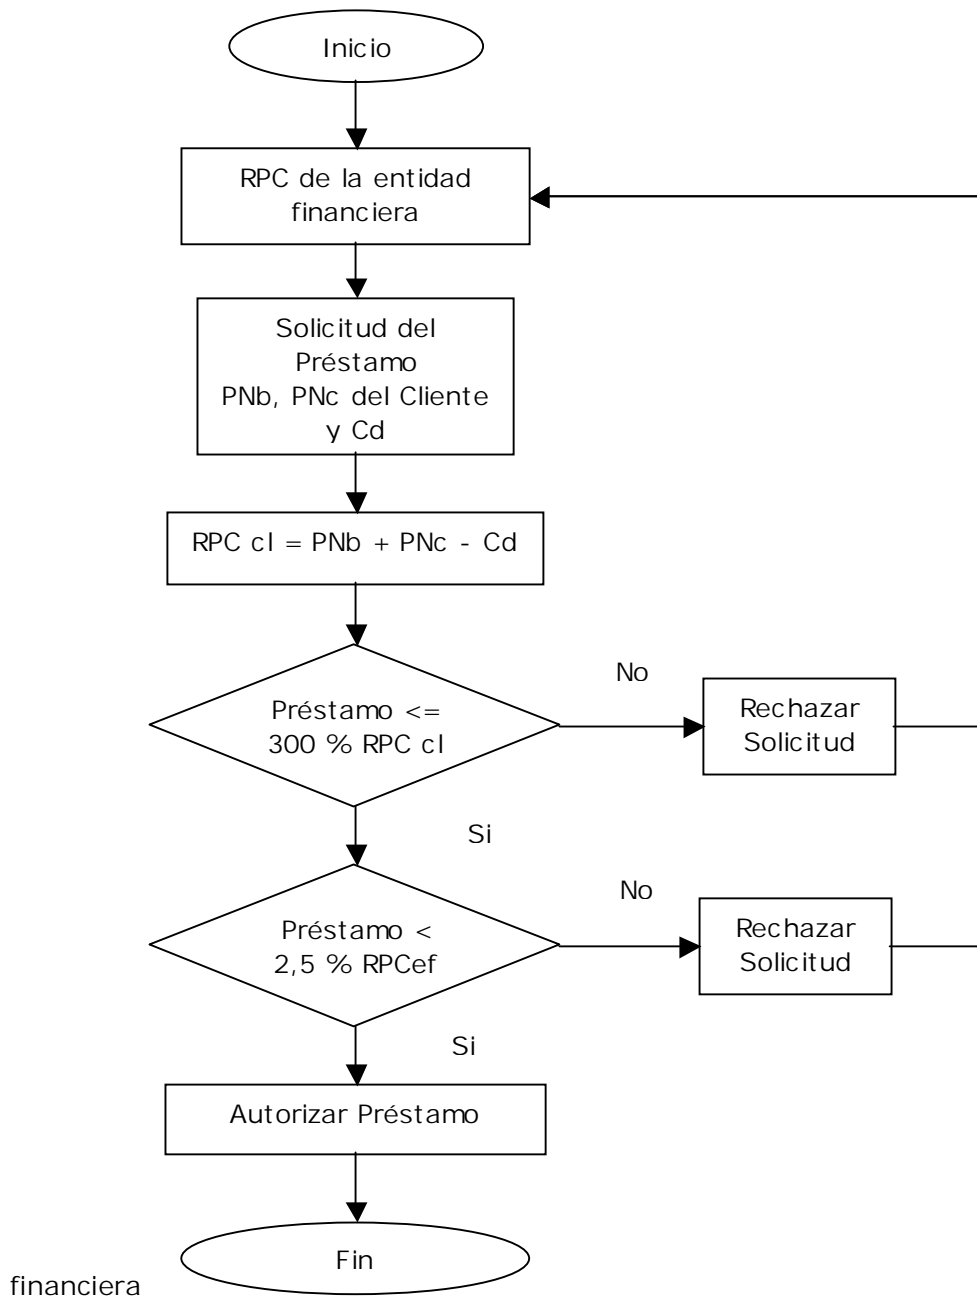
Según Normativa del BCRA

Algoritmo de otorgamiento de Crédito

$$RPCcl = RPC \text{ del cliente}$$



RPCef = RPC de la entidad



Bases De Datos Para Investigación De Resultados Financieros

Para la concreción de nuestra investigación, resulta necesario contar, mínimamente, con datos de los estados contables de un número importante de empresas. Hasta hora no hemos tenido éxito en la obtención de esos datos, ya que los Balances publicados en Internet (por ejemplo, en la web de la Comisión Nacional de



Valores), muchas veces resultan incompletos y no permiten compararlos en el tiempo o entre empresas.

En otros países puede accederse a publicaciones que permiten el análisis de datos, si bien no nos sirven como fuente. Las denominadas Centrales de Balances en España, por ejemplo, sirven de basamento empírico a una importante actividad de investigación académica⁹. Si bien las empresas españolas se muestran tan reticentes como las nuestras a publicar su información, hoy existen en ese país Bases de Datos que permiten comprender la coyuntura económica, la realidad por sector, localización, etc., y además permiten detectar modelos de comportamiento empresarial para explicar y predecir decisiones financieras.

Si bien tienen limitaciones, como el hecho de ser datos agregados referidos a determinado período, permiten establecer ratios estándares para una región o un tipo de actividad. Sobre esta base podrían aplicarse tecnologías innovadoras de búsqueda de conocimiento que aportarían importantes conclusiones a los investigadores del ámbito financiero empresarial y fundamentalmente a los tomadores de decisiones.

La existencia de Bases de Datos Financieros nacionales e internacionales constituye una valiosa fuente de información y sería deseable que en nuestro país se construyeran reservorios de datos similares para la detección de pautas necesarias para la investigación.

Otras experiencias

En el mismo marco de Análisis Financiero podremos establecer diversas áreas de aplicación:

- Predicción de tendencias de mercado (Stock Market Forecasts)¹⁰. El objetivo es la predicción de los tiempos óptimos para la venta de acciones en la Bolsa de Tokio y el análisis de la estructura de la red con el fin de deducir del modelo los factores que determinan las fluctuaciones de precios más

⁹ MEDINA, U., et.al, "Las Bases de datos en la investigación de la situación financiera y resultados de la empresa", Revista Española de Financiación y Contabilidad, Vol.XXIX, N.105, set 2000, pp.743-780

¹⁰ KIMOTO, T., ASAKAWA, K., "Stock Market Prediction System with modular Neural Networks", Proceedings of the IEEE International Conference on Neural Networks, Vol.II, San Diego, Calif., 1988, pp.1-6



significantes. La Red se ocupa de identificar la relación entre los índices existentes y los tiempos de compra y venta de acciones.

- Predicción de mercado de opciones (Options Market Forecasts)¹¹. El objetivo fue prever el mejor momento para la venta de derechos de opciones, basados en las tendencias de precios de acciones. Para ello utilizaron dos tipos de redes, resultando una superior cualitativamente, mientras que la segunda resultó más veloz.
- Predicción de ratios de control de cambios (Exchange Rates Forecasts)¹². Partiendo de la idea de que el mercado de acciones sigue una tendencia "casual" y por lo tanto resulta imposible predecirla, se utilizó una red neuronal, y se obtuvieron resultados muy cercados a la realidad. Luego de esto, el autor se dedicó a la compra y venta, con buenos resultados personales.
- Predicción de quiebras (bankruptcy forecasts)¹³. Se utilizaron un conjunto de cinco indicadores, con una red cuyo objetivo era determinar si la compañía analizada quebraría o no. Siempre los resultados obtenidos con la red resultó superior al análisis multivariado.
- Clasificación de stocks (stock classification)¹⁴.

La búsqueda del producto

Por tratarse de una investigación aplicada, nos orientamos hacia el desarrollo de un software que realizara el diagnóstico y la evaluación financiera, aún reconociendo nuestras limitaciones técnicas para su concreción.

¹¹ BAILEY, D.L., FEINSTEIN, J., "Option Trading Using Neural Networks", *Neuro Times*, 1989, pp.395-402

¹² Colin, A. "Exchange Rate Forecasting at Citybank London" *The fourth European Seminar on Neural Computing*, London, UK, 1991

¹³ Odom, MD, Sharda, R. "A Neural Network Model for Bankruptcy Prediction", *Proceedings of the IEEE International Conference on Neural Networks*, Vol.II, San Diego, Calif., 1988, pp.163-167

¹⁴ Dutta, S., Schekhar, S., "Bond Rating: a non-conservative Application of Neural Network", *Proceedings of the IEEE International Conference on Neural Networks*, Vol.II, San Diego, Calif., 1988, pp.443-450



Este objetivo excede las incumbencias de los profesionales en Ciencias Económicas, y a la vez nos lleva a preguntarnos acerca del límite de nuestra función como investigadores y como profesionales, ya que la dependencia de los técnicos en la toma de decisiones acerca de la implantación de los sistemas en general se evidencia en estos casos, en los cuales resulta difícil tomar una decisión correcta.

De la tarea podemos extraer algunas conclusiones que resultan válidas:

KAPPA-PC

Se trata de una cáscara (kernel) de sistema experto, que trabaja bajo Windows con una estructura rígidamente orientada a objetos. Cabe mencionar que la versión a la cual tuvimos acceso a los efectos de esta investigación no incluye el módulo correspondiente a la generación de un programa ejecutable.

Asesorados por técnicos en el uso de la herramienta, emprendimos la tarea de definir los objetos (clases y subclases) generando el correspondiente árbol con sus instancias.

A partir de este punto, lográbamos capturar los datos de Balances y generar el conjunto de ratios a analizar. Utilizando el Object Browser obteníamos la siguiente estructura:

Una vez ingresadas las reglas y los objetivos (goals), los mismos se van integrando hasta brindar la salida deseada; esto es, el diagnóstico acerca de la situación financiera del ente.

Ventajas:

- Es una herramienta de desarrollo posible de utilizar con un entrenamiento básico.
- Gracias a la estructura de objetos, puede ser modificado desde distintos módulos.
- Genera archivos de código ANSI, C++ o GUI runtimes.



Desventajas

- En el módulo base no se contempla la creación de un programa ejecutable, lo que dificulta su distribución

Programación Mediante Un Lenguaje

Si bien Kappa PC permitía la interacción con módulos de programación tradicional, se tomó la decisión de desarrollar el prototipo en lenguaje VisualBasic.

El proceso de implementación fue rápido, ya que en el mismo se tomaban rutinas provistas por el entorno de programación, sobre todo en lo referente a la aplicación de Lógica Difusa, no contemplada en el intento anterior.

Debido a las dificultades en el manejo de las reglas, surgió la necesidad de sistematizarlas. Esto originó la creación de un lenguaje de marcado específico, derivado del XML, que se denominó XKBL¹⁵ (Extensible Knowledge Base Language).

Ventajas

Utilización de software legal, propiedad de uno de los miembros del grupo, con el consiguiente acceso a bibliografía y documentación necesarias para el desarrollo

Desventajas

Muy complejo en el manejo de reglas, para las cuales el lenguaje no provee la debida estructura, ya que se trata de un lenguaje orientado a eventos y no a objetos.

Utilización de software gratuito

A continuación, se optó por utilizar un motor de inferencias de sistema experto de uso gratuito que permite el ingreso de reglas desde el soporte XKBL desarrollado por uno de los miembros del grupo.

El mismo se denomina CLIPS y constituye un motor de inferencias de sistema experto que captura las reglas generadas en XKBL y convertidas al formato CLIPS mediante una aplicación específica y emite un diagnóstico, justificado mediante la enunciación de las reglas involucradas.



Ventajas

- Permite la actualización y anidación de reglas, tanto en forma local como remota, con un buen nivel de independencia entre reglas y proceso.

Desventajas

- El producto actual es poco amigable
- Debe realizarse el proceso de conversión de reglas para ser procesadas.

Hacia el futuro

Las posibilidades futuras del producto se darán en dos sentidos posibles: análisis cuantitativo (índices obtenidos a partir de datos de Balances) y análisis cualitativo (indicadores provenientes de las transacciones).

En lo cuantitativo, resulta necesario capturar datos de los Estados contables en forma automática, lo que se verá favorecido cuando se haya generalizado el uso de XBRL (eXtensible Business Reporting Language), no como una información estática (proveniente del ingreso manual de datos) sino como un flujo permanente de bits que las aplicaciones deberán generar en tiempo real.

En lo cualitativo, la información surgirá de la operatoria normal del ente, contando con un almacén de datos (Datawarehousing) y procesadas con herramientas como Datamining.

Hemos tratado de brindar una herramienta para las empresas destinada a la autoevaluación del riesgo crediticio, con el objeto de reducir los costos de gestión de créditos, que a la vez sirva de fundamento del planeamiento estratégico y toma de decisiones gerenciales. Para ello necesitamos conocer las pautas que toman en cuenta las entidades crediticias en la seguridad de que las mismas son determinantes de la potencialidad financiera de las empresas.

El producto de dicho esfuerzo no está terminado aún, como nunca lo están los sistemas que desarrollamos. Como siempre decimos, estamos ante la enésima versión de un prototipo que seguirá evolucionando y que puede mostrarse en el estado en que

¹⁵ DÍAZ, Daniel, "XKBL, eXensible Knowledge Base Language", publicado en la Facultad de



se encuentra; constituye un intento de modelar las variables que intervienen en el proceso de diagnóstico y toma de decisiones de tipo financiero.

El trabajo hasta aquí expuesto constituye una breve reseña y a la vez un llamado de atención, en cuanto a las posibilidades y los logros en este campo de la ciencia en la cual se entrecruzan los conocimientos de expertos en finanzas, los aportes de la tecnología informática y sobre el cual nosotros, como profesionales de Empresas tenemos tanto que aportar.

Bibliografía:

BAILEY, D.L., FEINSTEIN, J., "Option Trading Using Neural Networks", Neuro Times, 1989, pp.395-402

COLIN, A. "Exchange Rate Forecasting ar Citybank London" The fourth European Seminar on Neural Computing, London, UK, 1991

DÍAZ, Daniel, "XKBL, eXensible Knowledge Base Language", publicado en la Facultad de Ciencias Económicas y Estadística.

DUTTA, S., SCHEKHAR, S., "Bond Rating: a non-conservative Application of Neural Network, Proceedings of the IEEE International Conference on Neural Networks, Vol.II, San Diego, Calif., 1988, pp.443-450

GARTNER GROUP "Breakthrough Banking Applications", enviada al seminario Profitable Data Warehousing Strategies for Financial Institutions, Atlanta, Georgia, 12 al 13 de febrero de 1996.

IOVALDI, Raúl H., "Inteligencia Artificial y Aprendizaje: investigación y metodologías", UNR editora, 2001, Rosario.

KIMOTO, T., ASAKAWA, K., "Stock Market Prediction System with modular Neural Networks", Proceedings of the IEEE International Conference on Neural Networks, Vol.II, San Diego, Calif., 1988, pp.1-6

MEDINA, U., et.al, "Las Bases de datos en la investigación de la situación financiera y resultados de la empresa", Revista Española de Financiación y Contabilidad, Vol.XXIX, N.105, set 2000, pp.743-780

ODOM, MD, SHARDA, R. "A Neural Network Model for Bankruptcy Prediction", Proceedings of the IEEE International Conference on Neural Networks, Vol.II, San Diego, Calif., 1988, pp.163-167

RUSSELL ,STUART, NORVIS, PETER, "Artificial Intelligence: a modern approach", Prentice Hall series Inteligencia Artificial, 1995, New Jersey.

SAGRISTÁ, Ricardo El Plano, Asociación Cooperadora de la Facultad de Ciencias Económicas y Estadísticas, 1997, Rosario



Octavas Jornadas "Investigaciones en la Facultad" de Ciencias Económicas y Estadística, noviembre de 2003.

VIVARACHO, Carlos Enrique Pascual, "Redes Neuronales Artificiales",
http://www.infor.uva.es/biometria/Documentos/informes_uva/EstadoArte/EstadoArte/EstadoArte.html