
Modelo de Evaluación de Créditos Financieros basados en Redes Neuronales orientado a Edpymes

Assessment Model of Financial Credits based on Neural Networks designed to Edpymes

Ana María Huayna D.¹, Vanessa Calvo Huaraz², Juan Carlos Huiman Sánchez

¹Universidad Nacional Mayor de San Marcos
Facultad de Ingeniería de Sistemas e Informática

²Universidad Ricardo Palma
Facultad de Ingeniería

ahuaynad@unmsm.edu.pe, vcalvo@grupobbva.com.pe, jhucal@hotmail.com

RESUMEN

Uno de los principales riesgos que afronta cualquier institución financiera es la probabilidad de que los deudores no estén dispuestos o no estén en condiciones de pagar sus préstamos. El presente artículo desarrolla un modelo enfocado a la solución de este problema; es decir, a disminuir el riesgo crediticio en clientes que soliciten algún préstamo o crédito a instituciones financieras. Este modelo está orientado a Edpymes, implementado con técnicas de inteligencia artificial, como son las redes neuronales entrenadas mediante el algoritmo Backpropagation.

Con la aplicación del modelo desarrollado, se logró reducir el índice de morosidad de un 3.5% a un 2.5%. Este 1% de diferencia representa aproximadamente unos 900 clientes visto a escala real.

Palabras clave: créditos, redes neuronales, algoritmo Backpropagation

ABSTRACT

The probability that debtors can not pay their loans is one of the main risks facing any financial institution. This work develops a model focused on resolving this problem, namely to reduce the credit risk at the time of a loan or credit is granted. This model is oriented to Edpymes, implemented with artificial intelligence techniques such as neural networks trained by the backpropagation algorithm. As a result of applying the model is achievement to reduce the credit risk of 3.5% to 2.5%. This 1% represents approximately 900 clients seen full-scale.

Keywords: credits, neural network, backpropagation algorithm

1. INTRODUCCIÓN

Hoy en día las empresas trabajan con gran volumen de información, que en algunos casos no es la correcta o está mal organizada. Las empresas deben ser capaces de obtener información valiosa de toda la gran cantidad de datos que tienen, y a partir de esta información obtener el conocimiento, el cual sería su activo más valioso.

Las grandes cantidades de datos con que cuentan las empresas obligan a encontrar métodos para analizar la información que tienen almacenada, surgiendo así el Datamining (Minería de Datos) como un medio para estudiar de una forma más profunda y eficiente los datos recolectados. Las Redes Neuronales es una técnica de Datamining la cual obtiene patrones y estructuras de información que pueden resultar muy valiosas para la industria, los bancos, las empresas comerciales, etc. Esta técnica busca poner al alcance de cada empresa la información que necesita en el momento preciso para que obtenga un máximo rendimiento en sus actividades

Las redes neuronales son un instrumento de más reciente aparición. En los últimos años han recibido considerable atención por parte del mundo académico y profesional, y ya empiezan a aplicarse en diversas organizaciones; principalmente en instituciones financieras donde se implantan modelos de Evaluación de Créditos, Análisis de la Solvencia basados en la computación neuronal.

El presente trabajo trata de representar la influencia de las redes neuronales en el mundo de las finanzas, específicamente, en la evaluación financiera, desarrollando para ello un modelo aplicado a entidades orientadas a la prestación de créditos como cooperativas, cajas municipales o Edpymes. En nuestro caso, el campo de aplicación será la Edpyme Edyficar. Para la solución al problema se optó por la Red Backpropagation por ser esta la red que más se adecua a la información y características recopiladas sobre la empresa en estudio, y que se ve reflejado en la presente investigación.

En la sección 2, describiremos los aspectos más relevantes sobre las Redes Neuronales, en la sección 3 se detalla el modelo a desarrollar y la herramienta teórica a utilizar, en la sección 4 se presentan las conclusiones, y en la sección 5, las referencias bibliográficas.

2. FUNDAMENTACIÓN TEÓRICA

2.1. Definición de Redes Neuronales (RN)

Las redes neuronales emulan ciertas características propias de los humanos, como la capacidad de memorizar y de asociar hechos.

Una Red Neuronal es una implantación, en equipos o programas informáticos, de un sistema de procesamiento de datos que simula funciones elementales de la red nerviosa del cerebro humano, siendo capaz de identificar la información relevante de una cantidad de datos, explicando el fenómeno o proceso que ha generado esos mismos datos.

En resumen, una Red Neuronal es "Un Nuevo sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: la neurona". [1]

2.2. Modelo biológico

La teoría y modelado de Redes Neuronales está inspirada en la estructura y funcionamiento de los sistemas nerviosos, donde la neurona es el elemento fundamental.

2.2.1. Neurona natural

En general, una neurona consta de un cuerpo celular más o menos esférico, de 5 a 10 micras de diámetro, del que salen una rama principal, el axón, y varias ramas más cortas, llamadas dendritas, como se aprecia en la Figura 1.

Una de las características de las neuronas es su capacidad de comunicarse. Las dendritas y el cuerpo ce-

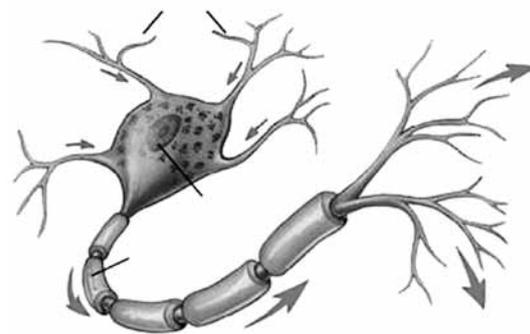


Figura N.º 1. Neurona y sus partes.

lular reciben señales de entrada; el cuerpo celular las combina e integra y emite señales de salida. El axón transmite dichas señales a los terminales axónicos, que distribuyen información.

2.2.2. Red neuronal biológica

El sistema de neuronas biológico está compuesto por neuronas de entrada (sensores) conectados a una compleja red de neuronas "calculadoras" (neuronas ocultas), las cuales, a su vez, están conectadas a las neuronas de salida que controlan, por ejemplo, los músculos.

Los sensores pueden ser señales de los oídos, ojos, etc. Las respuestas de las neuronas de salida activan los músculos correspondientes. En el cerebro hay una gigantesca red de neuronas "calculadoras" u ocultas que realizan la computación necesaria.

2.2.3. Neurona artificial

La neurona artificial recibe información de diversas fuentes, que están representadas por la letra X; así tenemos desde X1 hasta XN. La información no le llega a la neurona en estado puro, sino que es ponderada debido a que un tipo de información tendrá diferente importancia respecto a otro. Por eso a la información Xi se le multiplica por un peso designado por Wi. Lógicamente, si hay N puntos de información, habrá N pesos, uno por cada punto de información. Esto es representado en la Figura 2.

Al llegar a la neurona, todos los datos de las informaciones ponderados por sus pesos se suman. Esto es lo que se denomina la Regla de Propagación. Podría adoptar otras fórmulas, pero la más habitual es la simple suma de todas las entradas ponderadas que toma el nombre de Potencial Sináptico [9].

Cuando el resultado de la regla de propagación supera un cierto número, denominado umbral, entonces la

neurona se activa y el número resultante de la regla de propagación se "introduce" en una función denominada Función de Transferencia. Esquemáticamente, se podría representar de la siguiente manera:

$$H_i(t) > \theta \text{ entonces } f [H_i(t)]$$

$$\text{Donde: } H_i(t) = \sum_{j=1}^N X_j * W_j$$

$H_i(t)$ Es el potencial sináptico de la Neurona i en el momento t.

X_j La entrada de datos procedentes de la fuente de información j

W_j El peso sináptico asociado a la entrada Xj

Se puede escoger diferentes funciones para la función de transferencia.

Las cinco funciones de transferencia típicas que determinan los distintos tipos de neuronas son:

1. Función escalón
2. Función lineal
3. Función Sigmoidea
4. Función Tangente Sigmoidea
5. Función Gaussiana

2.2.3.1. Red Neuronal Artificial

Una neurona no tiene capacidad para realizar un proceso lógico, pero un conjunto de ellas sí. Por tanto, las neuronas se agrupan para realizar trabajos de cálculo lógico en redes. Las redes están compuestas de capas. Estas redes se interrelacionan entre sí mediante algoritmos, formando de esta manera el Sistema Neuronal, como se muestra en la Figura 3 [2].

Generalmente, una red neuronal típica tendrá tres capas: una de entrada de datos; otra oculta, donde se procesan los datos y; una tercera, de salida de los resultados. Cada una de las capas contendrá un número determinado de neuronas en función del diseño que haya decidido el analista y del tipo de trabajo que vaya a realizar la red. Todas las neuronas que contiene una capa se conectan con todas las neuronas de la siguiente capa. De esta manera, cuando una neurona obtiene

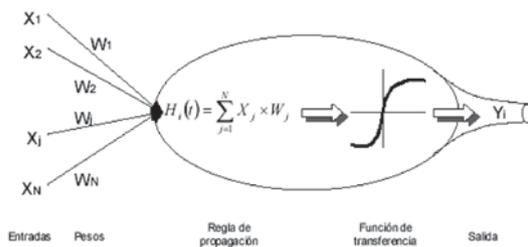


Figura N.º 2. Representación de una neurona artificial.

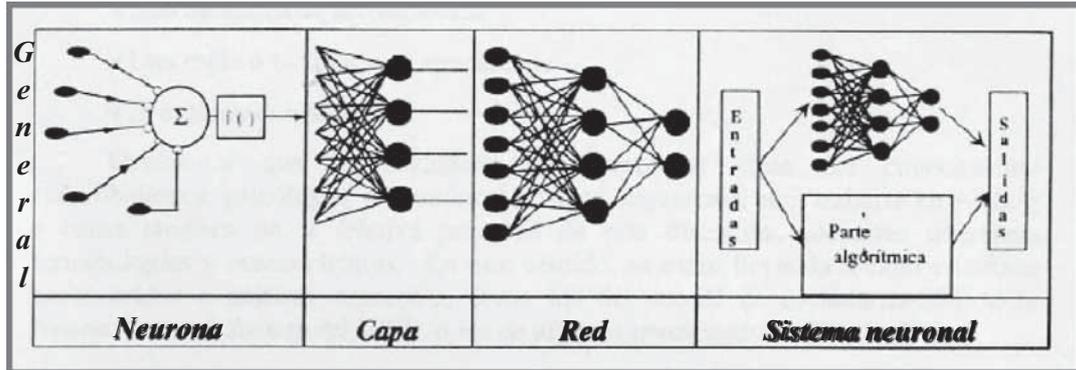


Figura N.º 3. Estructura jerárquica de un sistema basado en RNA

un resultado, lo envía a todas las neuronas de la capa siguiente. Este resultado será ponderado por cada neurona por el peso sináptico.

Para poder identificar a cada uno de los pesos sinápticos, se les añade un subíndice compuesto de dos números que identifican, por este orden, la neurona de destino (de la capa oculta) y la neurona de procedencia (de la capa de entrada).

$W_{j,i}$

En cada neurona de la capa oculta ocurre un proceso matemático consistente en la suma de las multiplicaciones de cada dato de información por sus pesos ponderados para determinar el potencial sináptico y que será el dato a introducir en la función de transferencia. El resultado de esta función en cada neurona de la capa oculta será su salida que se enviará a cada neurona de la capa de salida. Por tanto, cada neurona de la capa oculta tendrá tantas conexiones como neuronas

de salida hay y cada neurona de salida recibirá tantos flujos de información como neuronas existan en la capa oculta. Los flujos de información son ponderados por los pesos que unen las neuronas de la capa oculta con las neuronas de la capa de salida. En las neuronas de la capa de salida se realiza el mismo proceso llevado a cabo en las neuronas de la capa oculta. Al final, el resultado de la red será la salida de las neuronas de la capa de salida.

Este proceso se puede representar de manera matricial, que facilita la comprensión del sistema; para el ejemplo de la Figura 4, la matriz de entradas estará representada por X; mientras que la matriz de los pesos sinápticos viene representada por W y la matriz H representa los potenciales sinápticos de cada neurona de la capa oculta [9].

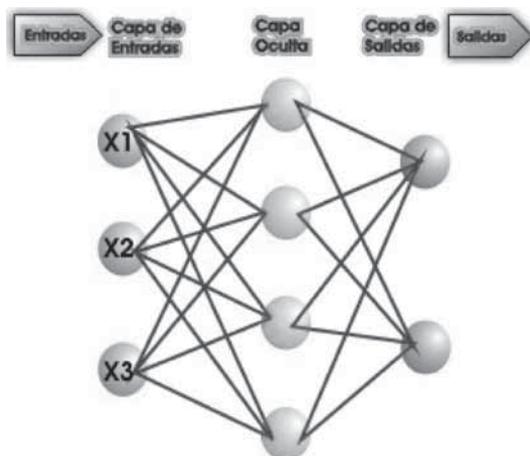


Figura N.º 4. Esquema de una Red Neuronal Artificial.

$$\begin{matrix} W_{1,2} & W_{2,2} & W_{3,2} & W_{4,2} \\ (X_1 X_2 X_3) * & \begin{bmatrix} W_{1,2} & W_{2,2} & W_{3,2} & W_{4,2} \\ W_{1,3} & W_{2,3} & W_{3,3} & W_{4,3} \end{bmatrix} & = & (H_1 H_2 H_3 H_4) \end{matrix}$$

$$(H_1 H_2 H_3 H_4) = (Y_1 Y_2 Y_3 Y_4)$$

$$\begin{matrix} (X_1 X_2 X_3 X_4) * & \begin{bmatrix} W_{1,1} & W_{2,1} \\ W_{1,2} & W_{2,2} \\ W_{1,3} & W_{2,3} \\ W_{1,4} & W_{2,4} \end{bmatrix} & = & (H_1 H_2) \end{matrix}$$

$$(H_1 H_2) = (Z_1 Z_2)$$

Cuando alimentamos las funciones de transferencia con los valores de la matriz de los potenciales sinápticos obtenemos la matriz Y de salidas de las neuronas de la capa oculta. Estas serán ponderadas por la matriz W' de pesos sinápticos que unen la capa oculta con la capa de salida. El resultado será la matriz H de potencial sináptico de la capa de salida que servirá para alimentar las funciones de transferencia de esta capa y que su resultado será la matriz Z de resultado de la red.

2.2.3.2. Funciones en las redes neuronales

a) Funciones base o de propagación

Representa el valor a su salida de una neurona y que se propaga a través de la red de conexiones unidireccionales hacia otras células de la red.

Existen dos tipos de funciones base:

** Función Lineal de Base*

Función de primer orden o de tipo hiperplano. El valor de red es una combinación lineal de las entradas.

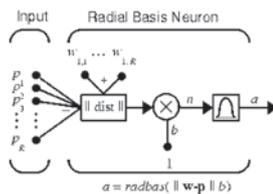
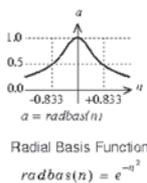
$$u_i(W, X) = \sum_{j=1}^n w_{ij} x_j$$

** Función de Base Radial*

Función de segundo orden o de tipo hiperesférico. El valor de red representa la distancia a un determinado patrón de referencia [18].

$$u_i(W, X) = \sqrt{\sum_{j=1}^n (x_j - w_{ij})^2}$$

En la función radbas o conocida como función de base radial, el argumento es la distancia entre el vector de pesos w y el vector de entrada p, multiplicada por la bia b. La bia b muestra la sensibilidad de la neurona para ser ajustada.



b) Funciones de transferencia

También llamadas de ejecución o activación, se encarga de transformar el valor de red expresado por la función de base u (w, x). Las funciones de activación más comunes son:

FUNCIÓN PASO	$f(u_i) = \begin{cases} 1 & \text{si } u_i > \theta_i \\ 0 & \text{si } u_i \leq \theta_i \end{cases}$
FUNCIÓN RAMPA	$f(u_i) = \begin{cases} u_i & \text{si } 0 \leq u_i \leq 1 \\ 0 & \text{si en otro caso} \end{cases}$
FUNCIÓN SIGMOIDAL	$f(u_i) = \frac{1}{1 + e^{-\frac{u_i}{\sigma}}}$
FUNCIÓN GAUSSIANA	$f(u_i) = ce^{-\frac{u_i}{\sigma}}$

Figura N.º 5. Funciones de transferencia.

2.2.3.3. Características de las Redes Neuronales

Existen diferentes características comunes en las redes neuronales. Estas son las siguientes:

Clasificación: Puede identificar datos y clasificarlos en clases. A diferencia de las técnicas tradicionales pueden generar para un problema concreto estructuras específicas de identificación de características.

Asociación: La red funciona como un proceso de recuperación de un dato a partir de una entrada relacionada con el dato almacenado.

Agrupamiento: Cuando no se produce una clasificación de los datos de entrada, es la red la que genera esta clasificación a medida que se va produciendo la señal.

Generalización: Las redes pueden detectar las relaciones subyacentes entre diferentes elementos, y por tanto, pueden extrapolar las relaciones numéricas presentes en los datos disponibles en situaciones similares.

Optimización: Cuando es necesario elegir la opción óptima entre diferentes alternativas, las redes proporcionan un procedimiento relativamente rápido para generar una solución subóptima que es suficientemente satisfactoria.

Predicción y control: La flexibilidad de las redes neuronales las hace adecuadas para la predicción, ya que el sistema va aprendiendo y puede seguir de manera versátil estos cambios [18].

2.2.4. Clasificación de las redes neuronales [13]

a) Según su naturaleza

- Redes Analógicas
- Redes Discretas (binarias)
- Redes Híbridas

b) Según el tipo de conexión

- Redes con conexiones hacia delante (feedforward)
- Redes con conexiones hacia adelante y hacia atrás (feedforward/feedback)

c) Según su topología

- Redes Monocapa
- Redes Multicapa

2.2.5. Tipología de las redes neuronales

Dependiendo de la estructura de la red existen varias tipologías:

- Perceptron,
- Backpropagation,
- Hopfield,
- Kohonen,
- Ward
- Redes Neuronales Probabilísticas (RNP)

2.2.6. Aprendizaje en las redes neuronales

Para encontrar los pesos sinápticos de una red neuronal se utilizan distintos tipos de aprendizaje o entrenamiento. Un aspecto importante respecto al aprendizaje es conocer cómo se modifican los valores de los pesos; cuáles son los criterios para cambiar el valor asignado a las conexiones cuando se pretende que la red aprenda una nueva información. Estos criterios determinan el tipo de aprendizaje, siendo dos los tipos principales de aprendizaje:

a) Aprendizaje Supervisado: En este aprendizaje hay que proporcionarle a la red los pesos sinápticos de entrada y salida para que la red los asocie. El hecho de conocer la salida implica que el entrenamiento se beneficia de la supervisión de un maestro: es como un profesor (patrones de salida) que indica y corrige los errores del alumno (red) hasta que este aprende a asociarlos. El supervisor comprueba la salida de la red y en caso

de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de que la salida obtenida se aproxime a la deseada. Se suelen considerar tres formas de llevar a cabo el aprendizaje:

- Aprendizaje por Corrección de error
- Aprendizaje por Refuerzo
- Aprendizaje Estocástico

b) Aprendizaje No Supervisado: En este tipo de aprendizaje, la red solo cuenta con los datos de entrada y de ahí debe extraer los rasgos característicos esenciales. La red se adapta gracias a las experiencias anteriores sin contar con la ayuda de un maestro, es como si un alumno dispusiera de material de estudio sin nadie que le controlara. Las redes con dicho aprendizaje no requieren de influencia externa para ajustar los pesos de las conexiones entre sus neuronas. La red no recibe ninguna información por parte del entorno que le indique si la salida generada en respuesta de una entrada es o no correcta. Suele decirse que estas redes son capaces de auto-organizarse. Suelen considerarse dos algoritmos de aprendizaje no supervisado:

- Aprendizaje hebbiano
- Aprendizaje competitivo y cooperativo

c) Aprendizaje Off Line: Se distingue entre una fase de aprendizaje o entrenamiento y una fase de operación o funcionamiento, existiendo un conjunto de datos de entrenamiento y un conjunto de datos de prueba que serán utilizados en la correspondiente fase. En las redes con aprendizaje OFF LINE, los pesos de las conexiones permanecen fijos después que termina el entrenamiento. Debido a su carácter estático, estos sistemas no presentan problemas de estabilidad en su funcionamiento.

d) Aprendizaje On Line: No se distingue entre fase de entrenamiento y fase de operación. Los pesos varían siempre que se presenta una nueva información al sistema. Debido a su carácter dinámico, el estudio de la estabilidad es un aspecto fundamental de estudio. [13]

2.2.7. Ventajas y desventajas en las redes neuronales

a) Ventajas

Las Redes Neuronales Artificiales se han aplicado a un gran número de problemas reales de complejidad considerable. Su ventaja más importante está en resolver

problemas que son demasiado complejos para tecnologías convencionales, problemas que no tienen un algoritmo de solución o que su algoritmo de solución es muy difícil de encontrar. Entre estas ventajas se incluyen:

- **Aprendizaje adaptativo:** Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.

- **Autoorganización:** La autoorganización consiste en la modificación de la red neuronal completa para llevar a cabo un objetivo específico.

- **Tolerancia a fallos:** En las redes neuronales, si se produce un fallo en un número no muy grande de neuronas y aunque el comportamiento del sistema se ve influenciado, no sufre una caída repentina. Hay dos aspectos distintos respecto a la tolerancia a fallos:

- Las redes pueden aprender a reconocer patrones con ruido, distorsionados o incompletos. Esta es una tolerancia a fallos respecto a los datos.
- Las redes pueden seguir realizando su función (con cierta degradación) aunque se destruya parte de la red.

La razón por la que las redes neuronales son tolerantes a los fallos es que tienen su información distribuida en las conexiones entre neuronas, existiendo cierto grado de redundancia en este tipo de almacenamiento.

- **Operación en tiempo real.** Para que la mayoría de las redes puedan operar en un entorno de tiempo real, la necesidad de cambio en los pesos de las conexiones o entrenamiento es mínima.

- **Fácil inserción dentro de la tecnología existente:** Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas.

b) Desventajas

El problema principal es que su funcionamiento es difícil de entender, esto se da debido a factores tales como:

- Las redes neuronales son un modelo que dificulta la comprensión.
- La relación entre pesos y variables es complicada.
- No permite una comprensión intuitiva de los resultados.

Otra desventaja importante es el tiempo de entrenamiento, y esto se debe a que el error decrece como una potencia del tamaño del entrenamiento.

Además, se requiere a menudo un significativo procesamiento previo de los datos para adaptarlos al de entrada que acepta la red [18].

2.2.8. Aplicaciones con las redes neuronales

Las principales características que diferencian a las redes neuronales de otras tecnologías de inteligencia artificial son:

- La capacidad de aprendizaje a partir de la experiencia.
- Su velocidad de respuesta una vez concluido el entrenamiento.
- Su robustez.

Las aplicaciones de las RNAs abarcan diversas actividades de muy diferentes campos. Estos son:

Finanzas

- Predicción de índices
- Detección de fraudes
- Riesgo crediticio, clasificación
- Predicción de la rentabilidad de acciones

Negocios

- Marketing
- Venta cruzada
- Campañas de venta

Tratamientos de texto y proceso de formas

- Reconocimiento de caracteres impresos mecánicamente
- Reconocimiento de gráficos
- Reconocimiento de caracteres escritos a mano
- Reconocimiento de escritura manual cursiva

Alimentación

- Análisis de olor y aroma
- Perfilamiento de clientes en función de la compra
- Desarrollo de productos
- Control de calidad

Energía

- Predicción del consumo eléctrico
- Distribución recursos hidráulicos para la producción eléctrica
- Predicción consumo de gas ciudad

Industria manufacturera

- Control de procesos
- Control de calidad
- Control de robots

Medicina y salud

- Ayuda al diagnóstico [4]
- Análisis de imágenes
- Desarrollo de medicamentos
- Distribución de recursos

Ciencia e Ingeniería

- Análisis de datos y clasificación
- Ingeniería Química
- Ingeniería Eléctrica
- Climatología

Transportes y comunicaciones

- Optimización de rutas
- Optimización en la distribución de recursos

3. METODOLOGÍA

Lo que se busca es plantear un Modelo Estándar de Evaluación de Créditos basado en Redes Neuronales que permita mantener en niveles razonables los riesgos en la concesión de préstamos; asegurando una buena rentabilidad en EDYFICAR.

Para su implementación se deben realizar las siguientes etapas:

- Filtrado de Datos
- Selección de Variables
- Extracción de Conocimiento
- Validación y Evaluación

3.1. Filtrado de datos

Los datos que obtengamos de las empresas clientes en las cuales aplicaremos el modelo, no siempre serán datos correctos, se deben ordenar los datos y dar importancia a aquellos que sean relevantes para la evaluación crediticia, es decir se realiza el filtrado de los datos, de forma que se eliminen valores incorrectos, no válidos, desconocidos; según las necesidades y el algoritmo a usar, también se procede a la reducción del número de valores posibles (mediante redondeo, clustering).

De la base de datos se debe extraer un conjunto de variables para cada empresa cliente, que formarán la base de patrones de aprendizaje. Se dispone también del output (salida) a aprender, que representa si la empresa devolvió o no el préstamo. Se puede asignar un 1 a las empresas que devolvieron el préstamo y un 0 a las que no.

3.2. Selección de variables

La selección de características reduce el tamaño de los datos para lo cual se eligen las variables más influyentes en el problema, sin sacrificar la calidad del modelo de conocimiento. Para el desarrollo del modelo se consideraron 9 variables de entrada:

Monto invertido. Es la cantidad de dinero que el cliente tiene invertido en el negocio.

Ingresos. Es el nivel de ventas que tiene el negocio, también se considera si tiene otros ingresos que no son generados por su negocio.

Porcentaje de utilidad. Es el margen de utilidad bruta que percibe el cliente como resultado de su negocio.

Gastos. Son los gastos en los que incurre el cliente dentro de su negocio así como los gastos por alimentación, escuela, etc.

Excedente. Es lo que le queda líquido al cliente; es decir lo que ahorra.

Deuda a proveedores. Son los saldos por pagar, como consecuencia de haber realizado compras al crédito o préstamos a otras instituciones.

Bienes. Conformado para nuestro caso por las propiedades de viviendas, terrenos, vehículos, mostradores, computadoras. En términos contables es conocido como inmuebles, maquinaria y equipos.

Patrimonio. Comprendido por el capital que aportan los socios, así como las utilidades o pérdidas que se van acumulando año a año.

Pasivo total. Es la suma de la deuda que tiene la empresa y/o persona a proveedores, estado (impuestos), instituciones financieras; a un año y mayores a un año.

3.3. Extracción de conocimiento

En esta fase se aplica una herramienta de software para obtener un modelo de conocimiento, que representa patrones de comportamiento observados en los valores de las variables del problema o relaciones de asociación entre dichas variables, para esto se requiere de un programa de redes neuronales. Hemos optado por la utilización de Tiberius Versión 5.4.3.

En la figura 6 se muestra un esquema del proceso de extracción de conocimiento. Para que la red neuronal ejecute una tarea es necesario entrenarla.

Se procede primero a la selección de patrones de aprendizaje, después se desarrolla la arquitectura neuronal (número de neuronas, tipo de red) estos dos puntos corresponden a la Selección de la Arquitectura.

Luego se procede a la Fase de Aprendizaje y a continuación la validación de los resultados en la Fase de Test

A continuación se detallarán cada una de las etapas:

a) Selección de la Arquitectura Neuronal:

La Arquitectura Neuronal consiste en seleccionar el número de neuronas, capas y su configuración. Esto es algo delicado, puesto que el aprendizaje de la red depende de ello.

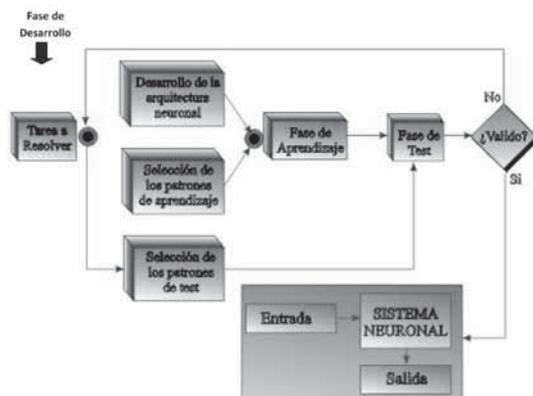


Figura N.º 6. Modo de trabajo con redes neuronales.

Utilizaremos un modelo de aprendizaje supervisado, ya que además de conocer las entradas de la red conocemos las salidas, y a partir de los patrones de salida se corrige la red hasta que este aprende a asociarlos. Por tal motivo, la herramienta seleccionada fue "Tiberius" en su versión 5.4.3.

Una vez ejecutado el programa se debe crear una red neuronal, eligiendo en primer lugar el número de capas. Luego se construye el modelo de red elegido: en este caso las neuronas de la capa de entrada serán 9, una por cada variable seleccionada. La capa oculta contará con cuatro neuronas para el procesamiento de la información; y la capa de salida tendrá una neurona, que puede tomar dos valores, cero para las empresas que no devolvieron el préstamo o son morosas y uno para las que si devolvieron el préstamo o no son morosas. Para el aprendizaje se utilizará el algoritmo Backpropagation.

Para crear el modelo en "Tiberius", se debe especificar:

- La base de datos que contienen los patrones de entrada a ser "aprendidos" por la red. Los cuales deben estar en un fichero en Excel o Access.
- Se debe indicar cuáles son las entradas a la red y cuál es la salida como se muestra en la Figura 7.

b) Fase de Aprendizaje

Originalmente la red neuronal no dispone de ningún tipo de conocimiento útil almacenado. Para que la red neuronal ejecute una tarea es preciso entrenarla; durante esta fase se puede producir la incorporación de nuevas neuronas o la pérdida de algunas de ellas. Si la red no aprende correctamente se pueden cambiar diversos parámetros y volver a entrenar. En todos los programas hay que seleccionar el algoritmo, que en este caso es el backpropagation así como una serie de parámetros. Con ello se está en condiciones de iniciar el aprendizaje.

Durante el aprendizaje en la mayor parte de los modelos se produce una variación de los pesos sinápticos, coeficientes del modelo, que miden la intensidad de interacción entre las neuronas. La red neuronal ajusta una función matemática (En el caso de Tiberius la función que emplea es del tipo sigmoïdal*) que trata de minimizar los errores, mediante un proceso de cálculo numérico iterativo.

Para llevar a cabo el entrenamiento en Tiberius preparamos un fichero con 80 patrones de entrada y los respectivos patrones de salida con los que se deben asociar.

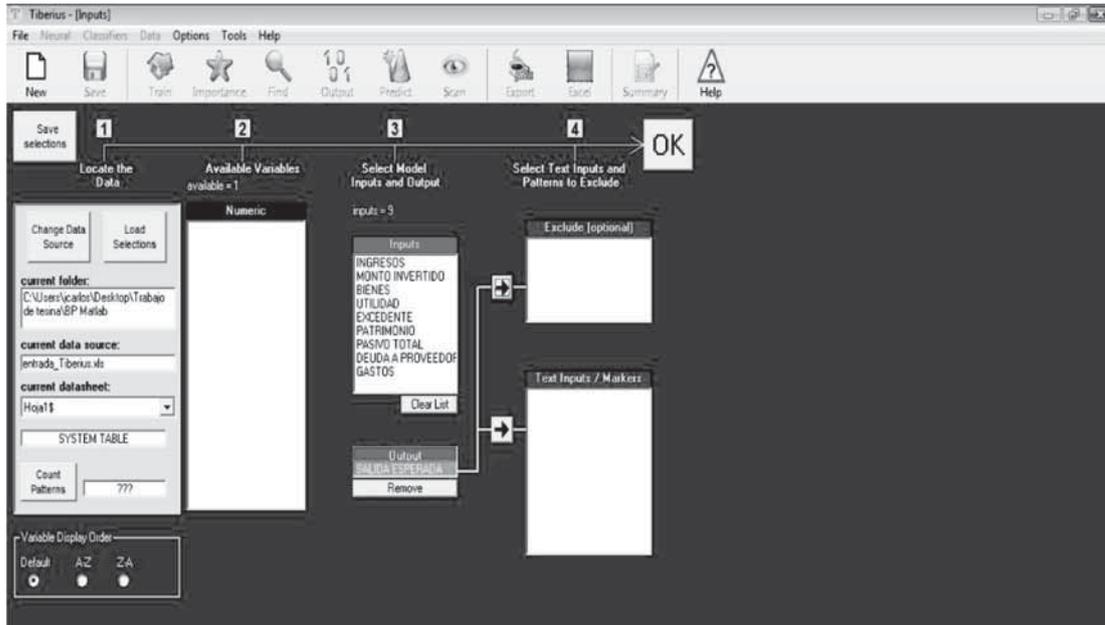


Figura N.º 7. Creación de modelo en Tiberius.

La mayoría de los programas presentan un gráfico o tabla en la que se observa los resultados del aprendizaje para cada iteración, tal como en la Figura 9.

En este caso, la red, configurada con distintas cantidades de neuronas en la capa oculta, fue capaz de clasificar correctamente todos los patrones de entrada que se le proporcionó como estímulo; mostrando solo dife-

rencia en el tiempo de entrenamiento, esto es, a mayor cantidad de neuronas en la capa oculta, menor era el tiempo que le tomaba a la red aprender.

c) Fase de Test

Tras la fase de aprendizaje se procede a una fase de test en la que, con nuevos patrones de entrada, se comprueba la eficacia del sistema generado. Si no es aceptable, se debe proceder a repetir la fase de desarrollo, utilizando un nuevo conjunto de patrones de entrenamiento, o bien modificando el sistema de aprendizaje o la arquitectura. Superada esta fase, la arquitectura, neuronas y conexiones, y los pesos sinápticos quedan fijos pudiendo el sistema operar en modo recuerdo. El modo recuerdo es el modo de operación normal del sistema: dada una entrada proporcionará una salida en

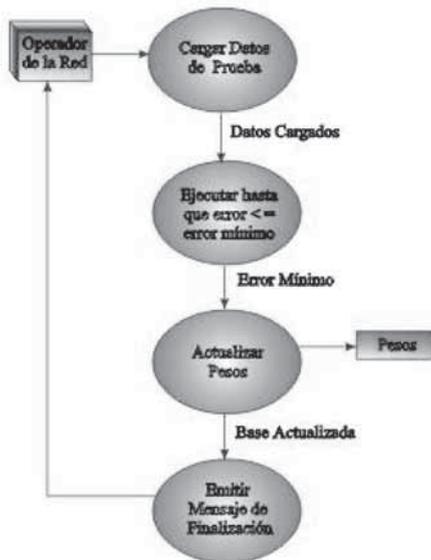


Figura N.º 8. Esquema de Entrenamiento de Red.

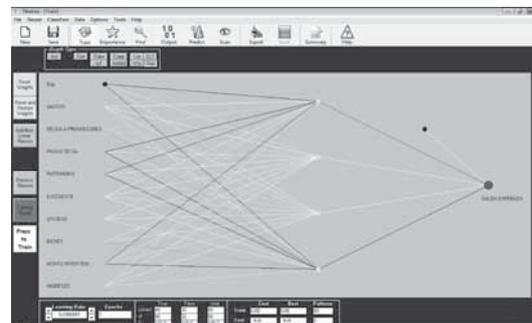


Figura N.º 9. Estructura de la red.

consonancia con el aprendizaje recibido (Aprendizaje Supervisado).

Es en esta fase donde se nota una clara diferencia entre las distintas configuraciones de la red para resolver este caso, y luego de analizar los porcentajes de aciertos en los resultados se escogió el de mayor porcentaje de aciertos.

Modelo	Learning Rate	Cantidad de Neuronas Ocultas	% True	% False	% Total
1	0,700000	5	91,7	75	85
2	0,000001	5	87,5	100	92,5
3	0,700000	4	87,5	100	92,5
4	0,000001	4	95,83	100	97,5
5	0,700000	3	87,5	100	92,5
6	0,000001	3	91,7	87,5	90
7	0,700000	2	87,5	100	92,5
8	0,000001	2	83,3	93,8	87,5

Tabla 1. Porcentajes de aciertos en los resultados.

Learning Rate es la Tasa de Aprendizaje (a).

% True representa el porcentaje de aciertos de empresas que devolvieron el préstamo.

% False representa el porcentaje de aciertos de empresas que no devolvieron el préstamo.

% Total es el porcentaje total de aciertos.

Los porcentajes de acierto de la red neuronal configura-



Figura N.º 11. Modelo para Evaluación de Créditos generado en Tiberius 5.4.3.

da con cuatro neuronas en la capa oculta son suficientemente satisfactorios, siendo evaluadas correctamente 39 de los 40 patrones ingresados para el test.

Tras una fase de Entrenamiento y de Test exitosos se procede a utilizar la herramienta "Development kit" de Tiberius, que permite generar una página Html o un proyecto en Visual Basic para predecir.

3.4. Validación y evaluación

Una vez obtenido el modelo, se debe proceder a su validación, comprobando que las conclusiones que arroja son válidas y suficientemente satisfactorias, en

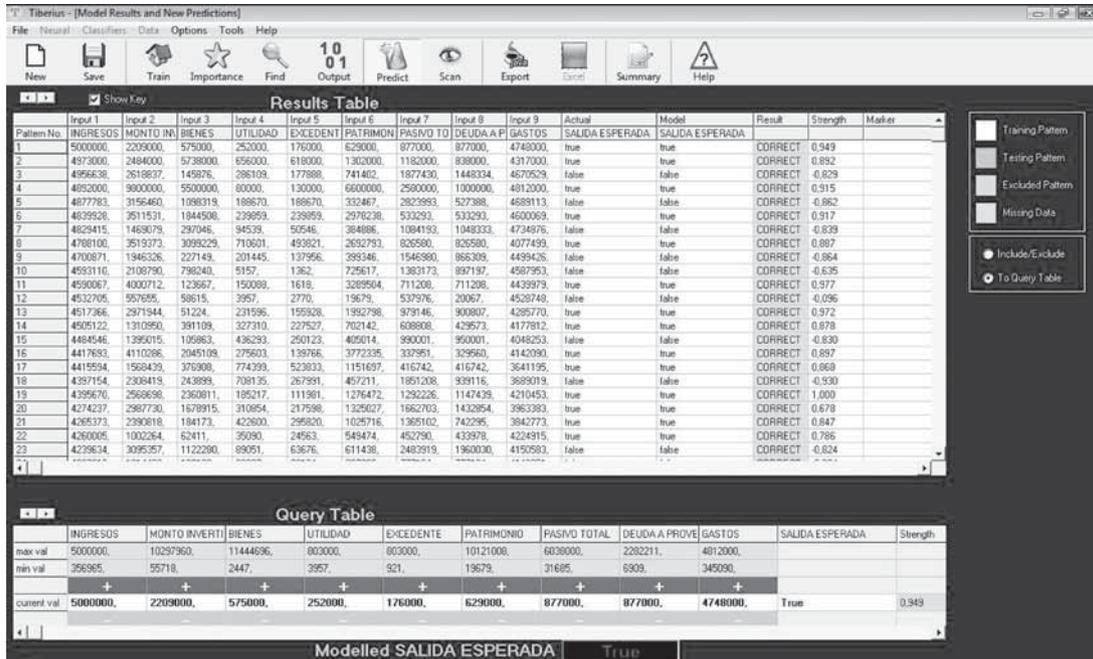


Figura N.º 10. Resultados del Testeo de la Red.

un entorno de producción simulado. Además, se debe determinar su efectividad en diferentes casos de aplicación. Si las pruebas arrojan resultados satisfactorios, el modelo queda comprobado y garantizado para su uso regular. En caso contrario, se deberá regresar a las fases anteriores y fortalecer el análisis para llegar al modelo final.

4. CONCLUSIONES

- Lo que se busca con la implementación del proyecto, es mantener y reducir la tasa de riesgo, minimizar el índice de morosidad, contar con una cartera de clientes sana y agilizar el proceso de evaluación de créditos.
- Para problemas de Clasificación son apropiados el uso de Redes Neuronales para la evaluación de créditos, ya que nos permiten filtrar mejor los datos los cuales suelen presentar un comportamiento no lineal.
- El análisis y selección de los criterios de evaluación, en consenso con los expertos, nos permitirá una mejor validez del modelo.
- El uso de la red Backpropagation, a pesar de invertir un tiempo considerable en su entrenamiento, los resultados que se obtienen son más satisfactorios. Además este tipo de red presenta propagación hacia atrás del error que se obtiene de cada una de las salidas, lo cual permite una mejor actualización de los pesos de conexión de cada neurona.
- La data de testeo debe ser real o muy cercana a la realidad con datos coherentes, que permitan obtener un buen modelo de evaluación.
- Así como se usaron variables cuantitativas para la construcción del modelo expuesto, recomendamos complementarlo usando variables de naturaleza cualitativas, para así captar todas las variables que intervienen en el proceso de crédito y hacer más real la evaluación.
- Se utilizó la herramienta Tiberius, para el modelado de la red neuronal. Esta herramienta permite la construcción de una red Backpropagation de 3 capas (una capa de entrada, una capa oculta y una capa de salida), pudiendo aumentar o disminuir la cantidad de neuronas en la capa oculta hasta lograr los resultados que se requieran.

5. REFERENCIAS BIBLIOGRÁFICAS

1. Luis Fernando de Mingo López. Nuevos métodos para el reconocimiento y clasificación de patrones con redes de neuronas, Universidad Politécnica de Madrid, Tesis Doctoral (2000), Madrid, España.
2. Marcelo Gutiérrez Márquez. Administración de carteras con redes neuronales mediante metodología Rolling, Universidad de Chile. Seminario para optar el título de ingeniero comercial (2004). Santiago de Chile.
3. María Clara Aristizábal Restrepo. Evaluación asimétrica de una red neuronal artificial: Aplicación al caso de la inflación en Colombia. Universidad Eafit. Tesis para optar título (2005). Medellín, Colombia.
4. Sáenz Bajo y M. Álvaro Ballesteros, Redes neuronales: concepto, aplicaciones y utilidad en medicina. Elsevier, (2002), 119-120.
5. Fredy Ocaris Pérez Ramírez, Horacio Fernández Castaño, Clasificación de riesgo en carteras de crédito aplicando metodología de redes neuronales, Revista Ingenierías Universidad de Medellín, volumen 6, N.º 10, (2007) 77-91.
6. Xavier Parra, Cecilio Angulo y Nuria Agell, Xari Rovira. Aproximación a un problema financiero mediante redes neuronales con funciones base radiales, Inteligencia artificial: Revista Iberoamericana de Inteligencia Artificial, N.º 14, (2001) 54-67.
7. Muñoz Rodríguez J.A. Aplicación de redes neuronales de aproximación a una línea de luz para reconstrucción 3d de objetos, Revista Mexicana de Física, N.º 005, (2004) 453-461.
8. Juan David Velásquez Henao, Lina María González Rivera. Modelado del índice de tipo de cambio real colombiano usando redes neuronales artificiales, Revista de la Escuela de Sistemas de la Universidad Nacional de Colombia. (2006) 319-336.
9. Chacón Murguía, Mario Ignacio. Clasificación de Defectos en Madera utilizando Redes Neuronales Artificiales, Computación y Sistemas, N.º 001, (2005). 17-27.
10. Calvo, Rafael A.; Alejandro, Ceccatto, Redes Neuronales: Hacia Un Modelo Computacional De La Mente. Revista Irice. N.º 5, (2000). 91-104.
11. Vásquez, Eduardo. ¿Qué son las Redes Neuronales? Revista Tópicos de Investigación y Posgrado, Vol: 2, N.º 3, (2001) 11-18.

12. Toro Ocampo, Eliana Mirledy, Molina Cabrera, Alexander, Garcés Ruiz, Alejandro, Pronóstico de bolsa de valores empleando técnicas inteligentes, Ternura, (2006). 57-66.
13. Bernal Reza, Miguel Angel, Redes neuronales, Avance y perspectiva, (2000). 31-35.
14. Espinosa Espinosa Ismael, Los robots flexibles y las redes neuronales, UNAM, Facultad De Ciencias, (2000) México D.F.
15. Simon Haykin. Neuronal Networks: A Comprehensive Foundation (en español), (2000) Canada.
16. Barandela Alonso, Ricardo, Procesamiento de la muestra para el entrenamiento del perceptrón multicapa, Editorial del Instituto Tecnológico de Toluca-Congreso Internacional de Ingeniería Electrónica, (2000) México D.F.
17. Alejandro Ferrer Quea, Formulación, análisis e Interpretación de los EE.FF. en sus ocho fases más importantes, Editorial Pacífico, (2004) Lima, Perú.