



UNIVERSIDAD CENTRAL
"MARTA ABREU" DE LAS VILLAS
VERITATE SOLA NOBIS IMPONETUR VIRILISTOGA
FACULTAD DE CIENCIAS ECONÓMICAS

TRABAJO DE DIPLOMA

**Propuesta de la aplicación de las Redes Neuronales Artificiales
en la inversión y gestión del crédito a clientes**

**Autor: Hai Ninh Quang
Tutor: Dr.C. Inocencio Raúl Sánchez Machado**

Santa Clara, junio de 2007

PENSAMIENTO

“Piensa mucho, habla poco, escribe menos”

-Proverbio Japonés

DEDICATORIA

A mi muy respetuoso profesor Dr. Víctor Manuel Figueroa Albelo

AGRADECIMIENTOS

Quería expresar mis más profundos agradecimientos a mis padres por su apoyo incondicional, por su ejemplo y dedicación que han sido motivo de mi admiración todos estos años.

A mis hermanos Mi, Moóc, y familiares por su aliento y cariño, siempre me han hecho sentir muy afortunado de tenerlos como familia.

A todos mis amigos que considero como hermanos, que me acompañaban en la vida y que siempre estuvieron dispuestos a ayudarme incondicionalmente, especialmente, a Quỳnh, Phong, Huy, Dũng, Nam, Đới, Đức, Lester Gali Cabrera, Harlan Domínguez Reyes, Yoanis Valdivia Martín, Yolisbey González Álvarez, Lusubilo Kabaghe.

A la Revolución cubana que me ha dado oportunidad de formarme como profesional.

A mi tutor el Dr. Inocencio Raúl Sánchez Machado por su apoyo desde la concepción de las ideas iniciales hasta la finalización de este trabajo; a la profesora Zulma María Ledesma Martínez por su preocupación y colaboración. Sin ustedes, no hubiera podido realizar este trabajo.

A todos mis profesores de la Facultad de Ciencias Económicas por sus enseñanzas, de misma manera a todo el personal de la Facultad.

A mi novia Li Chi (Sofía) por sus comprensiones y apoyo incondicional.

Un sencillo gracias a todas aquellas personas que de una u otra forma me han ayudado durante 6 años de mi vida en Cuba.

Ninh Quang Hai

RESUMEN

En un mundo globalizado, donde las exigencias de la competencia alcanzan niveles nunca antes imaginados, la inversión y gestión de créditos a clientes asume un importante papel. La influencia de la Revolución Científico Técnica sobre estos sistemas de gestión se ha visto reforzada y ha evolucionado a una gran velocidad; aunque los especialistas continúan insistiendo en la constante búsqueda de instrumentos que permitan garantizar la eficiencia y eficacia en la toma de decisiones.

Por tanto, en el desarrollo de este trabajo se ha intentado realizar un modesto esfuerzo por contribuir al mejoramiento de la inversión y gestión de créditos a clientes. Para ello se ha utilizado como herramienta fundamental la teoría de las Redes Neuronales Artificiales, la cual se ha relacionado en su aplicación con la intención de obtener resultados decisionales que garanticen la estabilidad de los sistemas financieros.

Finalmente, los resultados obtenidos han demostrado la viabilidad de aplicación de la teoría de Redes Neuronales Artificiales en función de la inversión y gestión de créditos a clientes.

ABSTRACT

In a globalized world, where the demands of competition have never reached such imagined levels before, the investment and management of credits to clients assume an important role. The influence of the Scientist-Technique Revolution on these management systems has been reinforced and it has evolved to a great speed; although specialists continue insisting in the constant search of instruments that allow guaranteeing the efficiency and effectiveness in decision making.

Therefore, in the development of this investigation, a modest effort is applied to contribute to the improvement of the investment and management of credits to clients. As fundamental tool, the theory of the Artificial Neuronal Network has been used, which relates its application with the intention of obtaining decisional results that guarantee the stability of the financial system

Finally, the obtained results have demonstrated the viability of application of the theory of Artificial Neuronal Networks in function of the investment and management of credits to clients.

INDICE

Índice

Introducción.....	1
Capítulo 1. Redes Neuronales Artificiales. Generalidades y aplicaciones	4
1.1. Redes neuronales biológicas.....	4
1.2. Redes Neuronales Artificiales.....	6
1.2.1. Definición	6
1.2.2. Estructura de una red neuronal.....	7
1.2.3. Entrenamiento de las RNA.....	11
1.2.4. Tipos de RNA.....	13
1.2.5. Ventajas y desventajas que presentan las RNA	16
1.2.6. Aplicación de las RNA en las finanzas	17
Capítulo 2. Gestión del riesgo de créditos.....	19
2.1. El crédito y la actividad crediticia	19
2.2. La gestión del riesgo.....	21
2.2.1. El riesgo	21
2.2.2. Principales modelos en la gestión del riesgo de créditos	23
2.2.3. Principales razones financieros para el análisis y gestión del riesgo	28
Capítulo 3. Aplicación de las Redes Neuronales Artificiales en el análisis del riesgo crediticio	31
3.1. Propuesta de un procedimiento metodológico de aplicación de las RNA en el análisis del riesgo crediticio	31
3.1.1. Definición de los objetivos.....	33
3.1.2. Preparación de la base de datos para el entrenamiento	33
3.1.3. Definición de la topología	33
3.1.4. Entrenamiento	33
3.1.5. Prueba.....	34
3.1.6. Operación.....	34
3.2. Caso de estudio	34
Conclusiones.....	42
Recomendaciones.....	44
Bibliografía	
Anexos	

INTRODUCCION

Introducción

La inversión y gestión de créditos a clientes es la decisión crítica fundamental de la actividad que rige las instituciones financiero crediticias (bancos). Los reguladores financieros utilizan los sistemas estandarizados de control, basados en evaluaciones externas para resolver esta tarea. Sin embargo, su carácter predictivo se complejiza debido al dinamismo e incertidumbre que impone la realidad económica actual, por lo que se requieren modelos de gestión más sofisticados y flexibles, cuyo desarrollo constituye uno de los principales retos del sector financiero.

Varios instrumentos han sido utilizados bajo determinadas circunstancias para la decisión de otorgamiento de créditos por parte de los bancos y en muchos casos han resultado eficaces: árboles de decisión, análisis de clusters, análisis discriminante entre otros. No obstante a ello, hay condiciones de la realidad económica concreta que indican la incapacidad de estos para resolver con optimalidad una decisión suficientemente argumentada.

En los últimos años, la teoría de Redes Neuronales Artificiales (RNA) ha aportado valiosas contribuciones en el campo de la economía y las finanzas, gracias a sus capacidades de aprender de la experiencia, lograr la generalización de casos anteriores a nuevos casos, extraer características esenciales a partir de entradas que representan información irrelevante, entre otras. Por tanto el problema central puede enunciarse como sigue:

¿Se puede contribuir a la toma de decisiones en la inversión y gestión del crédito a clientes aplicando las técnicas de RNA?

La *Hipótesis* de esta investigación se propone bajo el siguiente enunciado:

Con la implementación del nuevo procedimiento metodológico basado en la aplicación de las RNA se pueden tomar decisiones acertadas para la inversión y gestión de créditos a clientes.

En la realización de esta investigación se ha establecido en calidad de *Objetivo general*, el siguiente:

Elaborar una propuesta que contribuya a la toma de decisiones en la inversión y gestión del crédito a clientes a través de la aplicación de las técnicas de RNA.

En función de la estructura del informe de investigación se han perseguido los siguientes *Objetivos específicos*:

1. Explicar y conceptualizar la teoría de RNA.
2. Caracterización de la gestión del riesgo de crédito en las instituciones financiero – crediticias que a escala nacional e internacional justifican este tipo de investigación.
3. Elaborar un procedimiento metodológico basado en la aplicación de las técnicas de RNA para la inversión y gestión de créditos a clientes.

El desarrollo de la presente investigación se ha sustentado en las interrogantes problémicas que a continuación se enuncian:

1. ¿En qué se basa la teoría de RNA?
2. ¿En qué consisten los modelos fundamentales de la gestión del riesgo crediticio?
3. ¿Cuáles son las principales variables decisionales en la toma de decisiones en la inversión y gestión del crédito a clientes?
4. ¿Cómo se aplican las técnicas de RNA en la inversión y gestión de créditos a clientes?

La realización de este trabajo de investigación cuenta con la suficiente demostración de una necesidad práctica tomando en cuenta que el constante dinamismo de las sociedades y los mercados, obliga a ir buscando nuevas herramientas que vayan a la par con el desarrollo y que permitan tomar decisiones en forma eficiente, eficaz y correcta, tal es así en el sector de las finanzas. La teoría de RNA ofrece intensas posibilidades de aplicación y perfeccionamiento en el sector antes mencionado, por lo que su estudio y análisis merece una especial atención en el contexto actual.

Aunque este tema es relativamente novedoso, la investigación es viable, ya que se han publicado varios artículos sobre el tema de estudio, se cuenta con fuentes que ofrecen datos sustentados en estudios reales a escala internacional, sitios Web e investigaciones afines.

En este estudio se ha empleado el método dialéctico estructuralista, tomando en consideración que se ha utilizado el sistema financiero crediticio como un todo y se pretenden descubrir las relaciones causales y funcionales de las partes que forman ese todo, con el objetivo de descubrir lo esencial y lo secundario del problema que se investiga, lo cual debe permitir el descubrimiento de las características principales del objeto de estudio, así como sus contradicciones. Se hace uso de los métodos auxiliares de la inducción y deducción, siguiendo el camino de lo lógico y lo histórico.

Además, en el proceso de investigación son empleados categorías e instrumentos de las estadísticas y de otras ciencias afines que contribuyen a una mejor demostración de los objetivos que son planteados en el trabajo. Se aplicaron relaciones descriptivas entre las herramientas estadístico matemáticas y de inteligencia artificial y la inversión y gestión del crédito a clientes así como las relaciones estrechas entre ellos.

Para la presentación del informe final de esta investigación se ha definido una estructura de tres capítulos. En el primero de ellos, son abordados los basamentos conceptuales básicos de la teoría de RNA y una breve introducción de su aplicación en distintas áreas. En el segundo, se analizan directamente la actividad de inversión y gestión del crédito a clientes centrándose en la gestión de riesgo crediticio. Y en el tercero, se expone una propuesta metodológica basada en la aplicación de las RNA en la inversión y gestión del crédito a clientes.

Son insatisfacciones del autor no haber logrado disponer de una base de datos de sector financiero crediticio cubano suficientemente amplia y homogénea, aún cuando se pudo consultar trabajos presentados con anterioridad referentes a la aplicación de otros instrumentos estadísticos matemáticos para fines prácticos similares.

Es recomendable darle continuidad a los esfuerzos por aglutinar información factológica suficiente del sector bancario cubano que permita convertir la propuesta metodológica aquí presentada como un instrumento de trabajo permanente.

CAPITULO 1

Capítulo 1. Redes Neuronales Artificiales. Generalidades y aplicaciones

Al estudiar Redes Neuronales Artificiales (RNA), lo primero que se debe entender es el sustento de éstas, comprender su origen y la base de la cual se desarrollan. Las RNA nacen de la imitación del modelo neuronal biológico, o sea el sistema neuronal que todo hombre posee, el cual le permite desarrollar aprendizaje y por ende evolucionar.

Se considera importante comenzar con una idea general de cómo funcionan las redes neuronales biológicas, para luego ahondar en las RNA.

1.1. Redes neuronales biológicas

El cerebro consta de un gran número de neuronas (aproximadamente 10^{11}) altamente interconectadas entre sí, formando circuitos o redes que desarrollan funciones específicas. Una neurona típica recoge señales procedentes de otras neuronas a través de estructuras llamadas dendritas. La neurona emite impulsos eléctricos a lo largo de una fibra larga y delgada denominada axón, que se divide en millares de ramificaciones (Figura 1.1, 1.2).

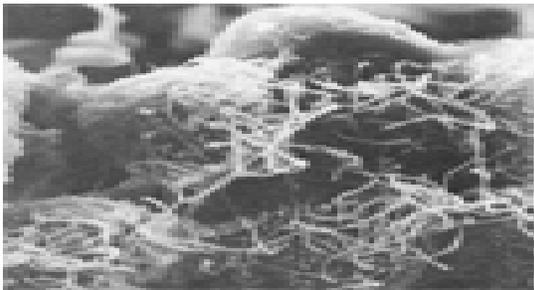


Figura 1.1. Un cúmulo de neuronas en el cerebro humano. Micrografía ampliada en 15.000 aumentos.

Fuente: Brain Research Institute. 1980

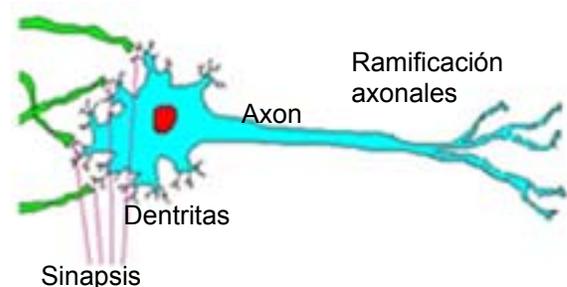


Figura 1.2. Esquema de una neurona y conexiones sinápticas.

Fuente: (Gondar 2001)

Las extremidades de estas ramificaciones llegan hasta las dendritas de otras neuronas y establecen unas conexiones llamadas sinapsis (Figura 1.3), en las cuales se produce una transformación de los impulsos eléctricos en un mensaje neuroquímico, mediante la liberación de unas sustancias llamadas neurotransmisores.

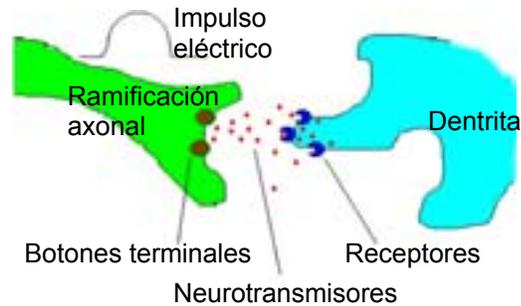


Figura 1.3. Detalle de una sinapsis
Fuente: (Gondar 2001)

El efecto de los neurotransmisores sobre la neurona receptora puede ser excitatorio o inhibitorio, y es variable, de manera que se puede hablar de la fuerza o efectividad de una sinapsis. Las señales excitatorias e inhibitorias recibidas por una neurona se combinan, y en función de la estimulación total recibida, la neurona toma un cierto nivel de activación (Figura 1.4), que se traduce en la generación de breves impulsos nerviosos con una determinada frecuencia o tasa de disparo, y su propagación a lo largo del axón hacia las neuronas con las cuales se produce la sinapsis.

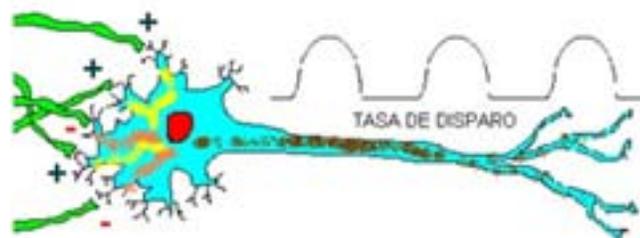


Figura 1.4. Activación y disparo de una neurona
Fuente: (Gondar 2001)

De esta manera la información se transmite de unas neuronas a otras y va siendo procesada a través de las conexiones sinápticas y las propias neuronas. El aprendizaje de las redes neuronales se produce mediante la variación de la efectividad de las sinapsis, de esta manera cambia la influencia que unas neuronas ejercen sobre otras, de esta manera se deduce que la arquitectura, el tipo y la efectividad de las conexiones en un momento, representan en cierto modo la memoria o estado de conocimiento de la red.

Las redes neuronales representan parte fundamental del cerebro, en el cual se generan todos los procesos necesarios para llevar a cabo una actividad determinada como respuesta a un estímulo generado en el ambiente. Su complejidad y gran alcance han llevado al hombre a estudiarlas y tratar de imitar su funcionamiento para lograr de alguna forma obtener el aprendizaje generado por éstas y poder aplicarlas en otros campos. Es así como nacen las RNA.

1.2. Redes Neuronales Artificiales

1.2.1. Definición

Existen múltiples definiciones de RNA:

(Haykin 1994): “Una red neuronal es un procesador masivamente paralelo distribuido que es propenso por naturaleza a almacenar conocimiento experimental y hacerlo disponible para su uso. Este mecanismo se parece al cerebro en dos aspectos:

- El conocimiento es adquirido por la red a través de un proceso que se denomina aprendizaje.
- El conocimiento se almacena mediante la modificación de la fuerza o peso sináptico de las distintas uniones entre neuronas.”

(Martin del Brio y Serrano 1995): “Sistemas de procesamiento que copian esquemáticamente la estructura neuronal del cerebro para tratar de reproducir sus capacidades, como por ejemplo, aprender de la experiencia a partir de las señales o datos del exterior, con el objetivo de construir sistemas de procesamiento de la información paralelos, distribuidos y adaptativos”.

Según (Gondar 2001), las neuronas se modelan mediante *unidades de proceso*. Cada unidad de proceso se compone de una red de conexiones de *entrada* (X_i), las cuales son ponderadas a través de un parámetro denominado *peso* (W_i); una *función de red* o de propagación (computa la entrada total combinada de todas las conexiones), un *núcleo central de proceso* (aplica la función de activación) y la *salida* (transmite el valor de activación a otras unidades) (Figura 1.5).

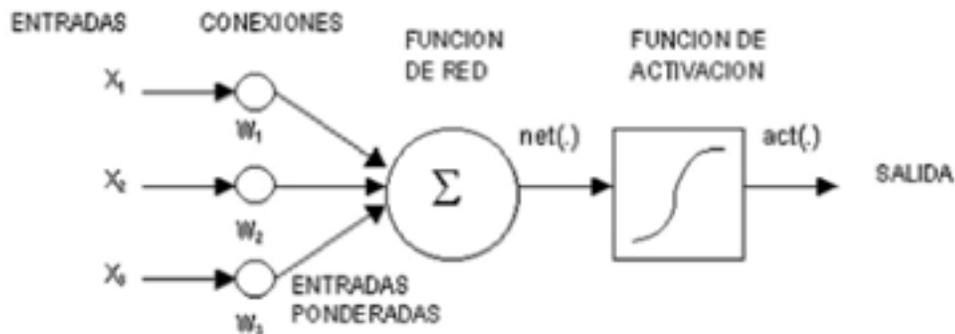


Figura 1.5. Unidad de proceso típica
Fuente: (Gondar 2001)

1.2.2. Estructura de una red neuronal

1.2.2.1. Capas

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*:

Capa Entrada: almacena la información bruta suministrada a la red o realiza un sencillo preproceso de la misma.

Capa Oculta: se encargan de recibir, procesar y memorizar la información.

Capa Salida: almacena la respuesta de la red para que pueda ser leída, dando un resultado final.

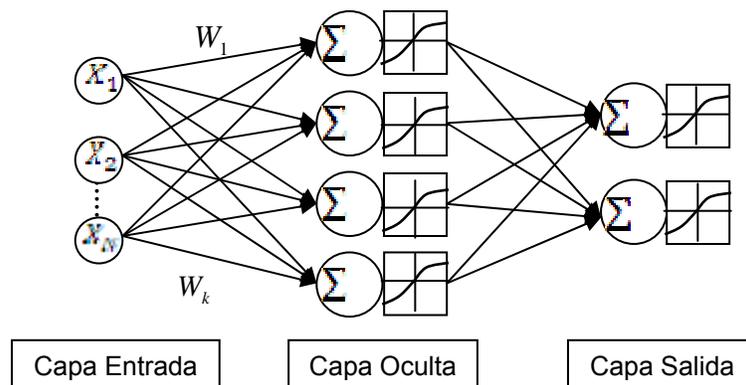


Figura 1.6. Representación de una RNA de 3 capas
Fuente: Elaboración propia

Generalmente, una RNA tiene tres capas (capa entrada, capa salida y una capa oculta). Cada una de las capas contiene 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 un resultado, lo envía a todas las neuronas de la capa siguiente.

1.2.2.2. Funciones

Función de propagación o de red

Esta calcula el valor de base o entrada total a la neurona, lo hace mediante la suma ponderada de todas las entradas recibidas, es decir, de las entradas multiplicadas por el peso o valor de las conexiones. La función de propagación proporciona el valor del potencial *postsináptico* de la neurona i en función de sus pesos y entradas, en un tiempo t .

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

Siendo:

$H_i(t)$ -- 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 X_j

Cuando el resultado de esta función 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 activación* o *Función de transferencia*. Esquemáticamente se podría representar de la siguiente manera:

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

Función de Activación

Es la característica principal o definitoria de las neuronas, es decir la que mejor define el comportamiento de la misma. Se usan diferentes tipos de funciones, desde

simples funciones de umbral a funciones no lineales. Con ésta se pretende calcular el nivel o estado de activación de la neurona en función de la entrada total.

De esta forma, la función de activación será aquel elemento de la *topología* de una red que permite calcular el estado de actividad de una neurona, transformando la entrada neta en un valor cuyo rango normalmente va de 0 a 1 ó de -1 a 1, dependiendo de su estado de actividad o inactividad. Así, una neurona podrá estar totalmente inactiva (0 ó -1) o totalmente activa (1) (Matich 2001).

Se puede escoger diferentes funciones para la función de activación. A continuación se presenta un breve repaso por unas de las funciones de activación más típicas con el objeto de familiarizar con ellas y saber las características que tienen.

Función escalón

Esta función se utiliza cuando la neurona tiene salidas binarias: 0, 1. La neurona se activa cuando el valor del potencial *postsináptico* es mayor o igual a cierto valor umbral.

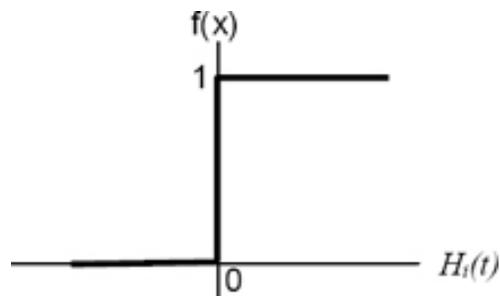


Figura 1.7 Función escalón

$$f(x) = \begin{cases} 1 & H_i(t) \geq 0 \\ 0 & H_i(t) < 0 \end{cases}$$

En este caso el umbral es cero. Cuando la función de propagación supera el valor cero, la función tomará valor uno. En caso contrario la función tomará el valor cero.

Función lineal

La función lineal o identidad responde a la expresión $f(x) = H_i(t)$. Una variación de la función lineal sería la función lineal a tramos donde la salida de la neurona sería la función identidad siempre y cuando el valor del potencial postsináptico estuviese dentro de un rango de valores. Al estar fuera del rango la función se torna constante.

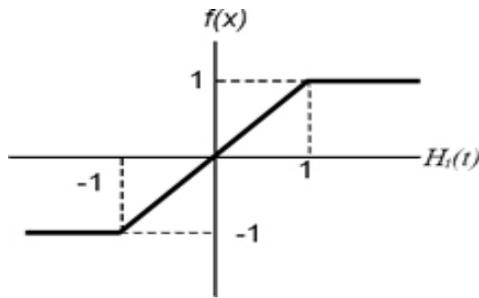


Figura 1.8. Función lineal a tramos

$$f(x) = \begin{cases} 1 & H_i(t) > 1 \\ H_i(t) & -1 \leq H_i(t) \leq 1 \\ -1 & H_i(t) < -1 \end{cases}$$

En este caso se aprecia como la función pasa a ser la función identidad a partir de que la función de propagación tome el valor \$-1\$ hasta el valor \$+1\$. Fuera de este rango la función se torna constante con un valor \$-1\$ desde \$-\infty\$ hasta \$1\$ y con un valor de \$1\$ desde \$1\$ hasta \$+\infty\$.

Función Logarítmica Sigmoidea

La salida de esta función siempre será continua en el rango entre cero y uno. Con esta familia de funciones se pueden utilizar datos continuos o digitales proporcionando salidas exclusivamente continuas.

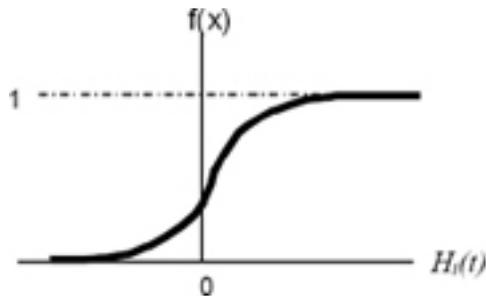


Figura 1.9. Función logarítmica sigmoidea

$$f(x) = \frac{1}{1 + e^{-H_i(t)}}$$

Aquí se observa como la función adopta valores muy próximos a cero cuando \$X\$ es pequeño, pero que según aumenta el valor en el eje de las abscisas la función pasa a ser creciente. Al principio la pendiente de la función crece hasta llegar a un punto de inflexión, momento en el cual la pendiente comienza a descender hasta llegar a cero, a partir del cual la función tiende a uno.

Función Tangente Sigmoidea

Esta es una de las funciones más utilizadas en las redes neuronales por su flexibilidad y el amplio rango de resultados que ofrece. Las ventajas de utilizar una tangente sigmoidea frente a una sigmoidea reside en que la segunda sólo ofrece resultados en el rango positivo entre cero y uno, en cambio la tangente sigmoidea da resultados entre -1 y 1 , por lo que se amplía a los números negativos los posibles resultados. La función tiene una tipología como la siguiente:

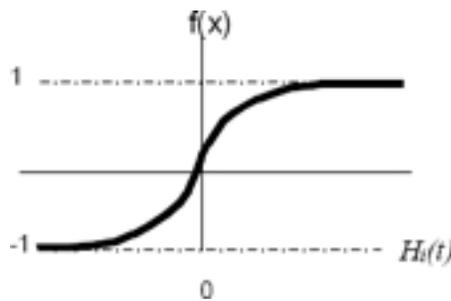


Figura 1.10. Función Tangente Sigmoidea

$$f(x) = \frac{1}{1 + e^{-2H_i(t)}} - 1$$

Aquí se observa como la función adopta valores muy próximos a cero cuando X es pequeño, pero que según aumenta el valor en el eje de las abscisas la función pasa a ser creciente. Al principio la pendiente de la función crece hasta llegar a un punto de inflexión, momento en el cual la pendiente comienza a descender hasta llegar a cero, a partir del cual la función tiende a uno.

El resultado que nos ofrece cada una de estas funciones será el dato de salida de la neurona que se dirigirá bien a otra neurona, bien al resultado final.

1.2.3. Entrenamiento de las RNA¹

El conocimiento necesario para resolver los problemas de determinado dominio de aplicación se introduce en la red neuronal a través de los pesos asociados a los enlaces entre las neuronas. A la determinación del conjunto de pesos que permite un trabajo satisfactorio de la red se conoce como entrenamiento de la red.

¹ Véase Pérez, Rafael Bello. 1993. *Curso introductorio a las redes neuronales artificiales*. Santa Clara: Departamento de Ciencia de la Computación. Universidad Central de Las Villas.

La determinación del conjunto de pesos de una red se puede realizar mediante tres métodos: programación prescriptiva de la red, aprendizaje adaptativo y aprendizaje no adaptativo.

El método de programación prescriptiva de la red se basa en fijar los pesos asociados a cada enlace. Esto significa que al crear la red, junto con la definición de su topología se asignan pesos a los enlaces. La programación prescriptiva de la red puede parecer una técnica rudimentaria, sin embargo, en algunos casos este método es útil, ya sea por la simplicidad de la red o por el conocimiento que se tiene sobre el significado de las conexiones.

Cuando la red no se programa prescriptivamente es necesario realizar un proceso de aprendizaje el cual permite calcular el valor de cada peso a partir de un conjunto de ejemplos típicos del dominio de aplicación, a este conjunto se le denomina conjunto de entrenamiento.

El resultado deseado del proceso de aprendizaje es que la red neuronal sea capaz de hacer generalizaciones. Si la red responde correctamente con alta probabilidad a patrones de entrada que no fueron incluidos en el conjunto de entrenamiento se dice que ha tenido lugar la generalización. Una red sin la capacidad de hacer generalizaciones es poco útil, pues si no es necesaria la generalización se puede simplemente almacenar las asociaciones en una tabla.

Para lograr una buena generalización el conjunto de entrenamiento debe contener una cantidad de ejemplos al menos varias veces mayor que la capacidad de la red, o sea, $N_p > N_w / N_y$ donde N_p denota la cantidad de ejemplos de entrenamiento, N_y la cantidad de neuronas de salida y N_w cantidad de pesos. Esto se puede entender intuitivamente notando que si la cantidad de grados de libertad de una red (N_w) es mayor que la cantidad de restricciones asociadas con la función de respuesta deseada ($N_p \times N_y$), el procedimiento de entrenamiento sería incapaz para restringir completamente los pesos en la red.

La forma en que se calculen los pesos divide a las técnicas de aprendizajes en adaptativas y no adaptativas. En el aprendizaje no adaptativo cada peso se calcula

directamente, utilizando una expresión matemática que incluye entre sus términos la información almacenada en el conjunto de entrenamiento. Ejemplos de este método son las reglas de aprendizaje del modelo de Hopfield y de la red de Hamming.

El aprendizaje adaptativo de la red se realiza a través de un proceso que comienza inicializando los pesos y luego iterativamente los pesos se van ajustando según alguna regla; como en el modelo Perceptron, el modelo ADALINE-MADALINE la Matriz Adaptativa, la red de Kohonen y el modelo de Carpenter/Grossberg.

1.2.4. Tipos de RNA

Existen múltiples tipos de clasificación de RNA, algunos autores las clasifican según el aprendizaje, según las capas, otros según conexión; existen además distintos tipos de RNA.

Según aprendizaje

Según (Palacios 2003) y (Matich 2001), un criterio habitual de clasificar las RNA es, según su aprendizaje, siendo este:

- Supervisado
- No supervisado
- Reforzado
- Híbrido

El primero menciona que el entrenamiento es controlado por un agente externo, quien determina la respuesta que debería generar la red a partir de una entrada determinada. En el caso contrario está el no supervisado, en el cual no existe un agente externo que determine la respuesta deseada, generando que la red sólo reconozca regularidades en el conjunto de entradas. Un aprendizaje que mezcla estos dos anteriores es el Híbrido, en el cual, algunas capas tienen aprendizaje supervisado y otras no supervisado. Similar al aprendizaje supervisado, está el Reforzado, en el cual se le indica a la red el error que comete (error global), es decir se indica el éxito o fracaso del resultado obtenido.

Según las capas

Las redes se dividen en:

- Monocapas
- Multicapas

Ambas se diferencian sólo en la cantidad de capas que posee la red neuronal, una en el caso de la monocapa y dos o más en las multicapas.

Según la conexión

- Feedforward
- Feedback

En las RNA Feedforward, las neuronas de cada nivel sólo están conectadas con las neuronas de los niveles posteriores por lo tanto la información se propaga hacia delante. Mientras que en las segundas, las neuronas pueden estar conectadas con neuronas de niveles previos, posteriores, o de su mismo nivel.

Según topologías clásicas

Según (Silva 2005), las topologías clásicas de RNA son:

- Perceptrón simple (Rosenblatt en 1962): Este tipo de RNA es el modelo más simple, es una red unidireccional compuesta por dos capas de neuronas, una de entrada y la otra de salida, por lo tanto en este modelo las neuronas de entrada únicamente envían la información a las neuronas de salida. El aprendizaje de este tipo de red es del tipo supervisado y se basa principalmente en la regla de corrección de error con respecto a la salida deseada.
- Perceptrón Multicapa: Este tipo de RNA es una ampliación del anterior, ya que incorpora uno o más niveles de unidades ocultas. Un Perceptrón multicapa es una RNA con alimentación hacia delante y está compuesta de varias capas de neuronas entre la entrada y la salida, permitiendo de esta manera establecer regiones de decisión mucho más complejas en comparación con el perceptrón

simple. Generalmente estas RNA se entrenan mediante el algoritmo *Backpropagation*².

- Redes Hebbianas: Este tipo de redes tiene un aprendizaje no supervisado. Se basa en la regla de Hebb, la cual dice que cuando una neurona activa a otra, la sinapsis queda reforzada. Este tipo de redes nos indica que si en el momento de la asociación entre las neuronas, dos o más de ellas se activan simultáneamente, estas actuarán en conjunto incrementando o potencializando la sinapsis, ya que ahora la activación o desactivación de una de ellas influye en la otra, por consiguiente se pueden activar varias neuronas en la salida.
- Redes Kohonen: Este tipo de RNA posee la capacidad de formar mapas de características de manera similar al cerebro. El objetivo de este modelo es demostrar que un estímulo externo (información de entrada) por si solo es suficiente para forzar la formación de estos mapas. Estos mapas se forman de la información de entrada, la cual mediante la semejanza de sus datos, forma diferentes categorías. Esta red utiliza el aprendizaje no supervisado de tipo competitivo, es decir, las neuronas compiten por activarse y sólo una de ellas permanece activa ante una determinada información de entrada, provocando que los pesos de las conexiones se ajusten en función de la neurona vencedora.
- Redes Hopfield: La red Hopfield funciona como una memoria asociativa no lineal, que puede almacenar internamente patrones presentados de forma incompleta o con ruido. Esta red está formada por neuronas conectadas simétricamente (al existir una conexión desde la neurona N_i a la neurona N_j , también existe la conexión desde N_j a N_i y ambas con el mismo peso $W_{ij} = W_{ji}$) y el conjunto permitido de valores de entrada y salida es $(0,1)$ pudiendo ser $(-1,1)$ o sea binario. Este modelo es similar al Perceptrón, pero presenta una característica adicional y es que las neuronas de la capa media, presentan conexiones de salida hacia otras neuronas de la capa media. Este hecho, hace que en esta capa se dé un feedback entre sus neuronas, de forma que al activarse una de las neuronas, las

² Backpropagation es un algoritmo para entrenar a la RNA que se emplea un ciclo de propagación-adaptación, en el que los pesos en la capa de salida se ajusta para reducir el error entre los resultados generados por la red y los deseados, luego los cambios realizados se propagan hacia la capa de entrada ajustando los pesos de las capas ocultas.

otras cambian su estado de activación, que a la vez hará cambiar el suyo. Por lo tanto, el patrón de activación se transmitirá sólo cuando se llegue a un equilibrio. Esta red no implica cálculo de pesos sinápticos ya que estos se mantienen constantes.

Según procesamiento

Existen modelos estáticos y dinámicos de RNA. Los modelos estáticos configuran una red con un conjunto de datos determinados, la entrenan y una vez que la red alcanza buen desempeño se fija su configuración y sus pesos, luego con esa red fija se prueba un conjunto de datos (testing) para evaluar finalmente el desempeño de la red. Los modelos dinámicos incorporan los datos del testing (extramuestral) dentro de la red y estos nuevos datos van modificando la red, por lo que la hacen dinámicas, ya que incorpora la nueva información.

1.2.5. Ventajas y desventajas que presentan las RNA

Ventajas

Debido a su constitución y a sus fundamentos, las redes neuronales artificiales presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante, etc. Esto hace que tengan numerosas ventajas, según (Hilera y Martínez 1994) estas son:

- Aprendizaje adaptativo. Capacidad de aprender a realizar tareas basadas en un entrenamiento o una experiencia inicial.
- Autoorganización. Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.
- Generalización. Facultad de las redes neuronales de responder apropiadamente cuando se les presentan datos o situaciones a los que no habían sido expuestas anteriormente.
- Tolerancia a fallos. La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener,

incluso sufriendo gran daño. Con respecto a los datos, las redes neuronales pueden aprender a reconocer patrones con ruido, distorsionados o incompletos.

- Operación en tiempo real. Los computadores neuronales pueden ser realizados en paralelo, y se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.
- Fácil inserción dentro de la tecnología existente. Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilita la integración modular en los sistemas existentes.

Desventajas

Según (Brunel 2005) las redes neuronales a pesar de todas las ventajas que tiene, también presenta desventajas, estas son:

- Las RNA constituyen un método de resolución de problemas creativo, es decir, que dada las especificaciones de un problema, se desconoce la topología (características de la RNA) con la que se va a solucionar del modo más eficiente.
- Una vez entrenada una red neuronal, se hace difícil interpretar su funcionamiento, aún más, no es fácil asegurar con qué grado de acierto responderá ante casos nunca vistos.
- Los modelos neuronales necesitan una herramienta de procesamiento poderosa. Esto se manifiesta principalmente en el proceso de aprendizaje, pero esto se puede contrarrestar con la facilidad de implementación en dispositivos de hardware específicos.

1.2.6. Aplicación de las RNA en las finanzas

En el área de finanzas existen múltiples problemas a resolver, muchos de ellos involucran complicados cálculos numéricos y difíciles estimaciones a realizar. Con el tiempo se han diseñado distintos software o programas para facilitar el cálculo de éstos y hacer más eficiente el proceso de análisis. Sin embargo los software muchas veces no son una solución adecuada para aquellos problemas de naturaleza compleja, no estructurados, que requieren alguna forma de reconocimiento de patrones y que involucran datos incompletos o ruidosos, para este tipo de casos es

cuando son usadas las RNA, para aquellos donde se requiere de agregar un componente de inteligencia al proceso de análisis.

Según (Aragón Torre, et al. 1997), existen al menos tres motivos, por los cuales, se están utilizando estos modelos frente a otro tipo de metodologías como pueden ser los modelos *ARIMA*.

- El primer motivo surge del hecho de que en las primeras simulaciones efectuadas, la metodología de las Redes se mostraba superior a las series temporales clásicas, cuando estas series no tenían un fuerte componente estacionario; se pensó que eso mismo podría ocurrir con los mercados financieros.
- En segundo lugar, las RNA permiten trabajar en principio más cómodamente con modelos multiperíodo y multivariable, sin tener que preocuparse de problemas como la multicolinealidad, ni tener la necesidad de especificar previamente el tipo de relación funcional entre variables.
- Por último, en los modelos de Redes se pueden introducir fácilmente indicadores tanto chartistas como fundamentales.

Las aplicaciones en finanzas e inversiones se pueden dividir según el problema que enfrentan. A continuación se muestran 3 categorías:

Banca	Finanzas	Seguros e Inversiones
<ul style="list-style-type: none"> – Clasificación Crediticia. – Aprobación de créditos. – Predicción del comportamiento de nuevos clientes. – Selección de buenas clases de riesgo. – Riesgo operacional. 	<ul style="list-style-type: none"> – Predicciones riesgo quiebra una empresa. – Medida de la volatilidad. – Precio de opciones. – Gestión de acciones. – Formación y Gestión de carteras. – Predicción de riesgos. – Gestión de Fondos de Pensiones y Fondos de Inversión. 	<ul style="list-style-type: none"> – Riesgo operacional. – Credibilidad. – Análisis de supervivencia. – Clasificación de Bonos. – Valoración de nuevos instrumentos. – Análisis técnico. – Análisis fundamental. – Administración de portafolios

Tabla 1.1 Aplicación de RNA en finanzas e inversiones
Fuente: (Ricote Gil 2003)

CAPITULO 2

Capítulo 2. Gestión del riesgo de créditos

El entorno competitivo que presenta hoy el sistema económico mundial obligan a las empresas se preocupen por obtener fuentes de financiamientos para poder realizar sus actividades ya sea para desarrollar sus funciones actuales o ampliarlas, así como el inicio de nuevos proyectos que impliquen inversión.

Existen diversas fuentes de financiamiento. Las más comunes de estas se clasifican en: internas y externas. Dentro de las fuentes externas, el financiamiento a través de créditos (comerciales o bancarios) es una de las fuentes de financiamiento más importantes de las empresas para sus actividades y asegurar el progreso de su actividad.

En este capítulo, se abordarán de forma general los principios de la gestión de riesgo crediticio tomando en cuenta su papel esencial en la inversión y gestión de créditos a clientes.

2.1. El crédito y la actividad crediticia

La palabra *crédito* viene del latín, *creditum* (sustantivación del verbo *credere*: creer), que significa "cosa confiada". Así "crédito" en su origen significa entre otras cosas, confiar o tener confianza.

En la vida económica y financiera se entiende por crédito, por consiguiente, la confianza que tenemos en la capacidad de cumplir, en la posibilidad, voluntad y solvencia de un individuo, por lo que se refiere al cumplimiento de una obligación contraída.

En este trabajo, el crédito se entiende por *cantidad de dinero que presta un banco o una caja de ahorros y que debe ser devuelta en un período determinado en las condiciones pactadas*³; y solo se concentran en dos tipos de créditos financieros: el crédito bancario y el comercial.

³Diccionario de Uso del Español de América y España VOX. Epes Editorial, S.L. 2005

El crédito bancario

Los bancos comerciales, cuyos préstamos aparecen generalmente en los balances general de las empresas como documentos por pagar, ocupan el segundo lugar de importancia como fuente de financiamiento a corto plazo. Aunque los bancos también hacen préstamos a largo plazo, la mayor parte de sus préstamos son de corto plazo (Weston y Brigham 1993).

En el ámbito bancario el análisis, medición, administración y gestión del crédito, adquiere una importancia capital por el importante volumen de recursos que moviliza la “industria bancaria”, afectando transversalmente a todos los sectores productivos, y por la propia estructura del balance de la empresa bancaria ya que gestionan activos mucho menos líquidos que los propios pasivos y a vencimientos mayores (Quesada, et al. 2000).

El crédito comercial

Desde el punto de vista del vendedor, siempre cuando se realiza una venta de mercancías o bienes de servicio a crédito, se crea una partida de activos denominada cuenta por cobrar. En general, las empresas preferían vender al contado en vez de vender a crédito, pero las presiones de la competencia obligan a la mayoría de las empresas a ofrece crédito (Weston y Brigham 1993). El objetivo fundamental del crédito a través de las cuentas a cobrar es conservar clientes actuales y atraer nuevos clientes incrementándose las ventas rentables, mediante la extensión de crédito a clientes dignos.

Debido a que una empresa típica tiene aproximadamente un 25% de sus activos invertidos en las cuentas por cobrar, su efectividad en la administración de éstas es muy importante para su rentabilidad y para su riesgo (Weston y Brigham 1993).

2.2. La gestión del riesgo

2.2.1. El riesgo

El riesgo se puede entender como *posibilidad de que se produzca un contratiempo o una desgracia, de que alguien o algo sufra perjuicio o daño*⁴.

Según la definición a la que se refiere este trabajo, el riesgo es *la variación potencial en el valor económico de una cartera de inversiones*.

El riesgo es consustancial a toda actividad empresarial y, por extensión, a toda inversión en general. En la medida que los resultados vengán determinados por la aparición y manifestación de unos u otros escenarios plausibles, previstos o no por los gestores y gerentes del cambio se estará en presencia de un determinado nivel de riesgo.

Los riesgos se pueden clasificar de la siguiente manera:

- El riesgo de crédito (o riesgo de incumplimiento): se define como la probabilidad de no recuperar el monto original y los intereses derivados del préstamo. Es el riesgo típico, tradicional y de mayor relevancia asociado a las operaciones de crédito, préstamo y aval.

El riesgo de crédito puede clasificarse de manera general en: Insolvencia, iliquidez, riesgo - país y otros.

- El riesgo de mercado, se relaciona con la alteración en el valor de las posiciones abiertas en activos subyacentes o en derivados en los mercados de capitales. Los riesgos de mercado son los más afectados por el proceso de globalización, en la medida en que las causas explicativas de la volatilidad de los precios de los activos son cada vez menos locales y mucho más sistémicas (sistema financiero global) (Quesada, et al. 2000).

La gestión del riesgo ha pasado, recientemente, de una consciente orientación al riesgo de crédito en los años setenta, a una orientación a los riesgos de mercado. Asimismo, en los últimos años, se ha cambiado de paradigma en lo referente a la importancia de la información en la gestión y administración del riesgo. Se ha pasado

⁴ Diccionario de Uso del Español de América y España VOX. Epes Editorial, S.L. 2005

de un manifiesto énfasis en el uso de la información histórica a una mayor relevancia en el uso de la información prospectiva (hacia el futuro). En la actualidad, ante una actitud de integración en la gestión de riesgos, los modelos de administración de los mismos se orientan hacia la gestión conjunta de resultados y riesgos y hacia la integración total de la información (centralización de la información) (Quesada, et al. 2000).

Las entidades financieras pueden adoptar diversos mecanismos para protegerse del riesgo de crédito. En general se pueden clasificar en mecanismos de carácter preventivo y mecanismos de tipo curativo.

Entre los riesgos de tipo preventivo se pueden encontrar los siguientes:

- Análisis previos de la situación económico-financiera del cliente.
- Vigilancia de riesgos.
- Obtención de informes comerciales.
- Scoring o análisis algorítmico de la operación.
- Rating.
- Entre otros.

Entre los riesgos de tipo curativo se podrían citar los que siguen:

- Asunción de sistemas de cobertura.
- Afianzamientos y garantías.
- Rigor documental.
- Seguros de crédito.
- Sistemas de recobro.
- Entre otros.

La prevención del riesgo de incumplimiento de la contraparte de las condiciones contractuales de las operaciones crediticias, bien por incapacidad de pago total o parcial del nominal del contrato (riesgo de insolvencia), bien por incumplimiento de los plazos pactados (riesgo de morosidad), ha sido la clave de la gestión del riesgo. Tratar de conocer ex-ante el comportamiento del deudor y prevenir los quebrantos que ocasionaría con su comportamiento ha dado lugar a diferentes modelos

orientados a prevenir, y paliar en su caso, los efectos derivados del posible impago o su probable demora en términos temporales.

2.2.2. Principales modelos en la gestión del riesgo de créditos

Existen modelos de carácter cualitativo y cuantitativo en los que el grado de sofisticación es generalmente el resultado de la evolución de sistemas anteriores, pasando de análisis más primitivos y que no resuelven todas las cuestiones que se plantean a desarrollos más recientes de técnicas de mayor nivel de sofisticación para la toma de decisiones. Las experiencias negativas de las entidades, debidas a selección adversa y al riesgo moral⁵, inducen a la búsqueda de metodologías de análisis, en las que el componente subjetivo tenga menos peso, orientándose a modelos analíticos que trabajen con datos objetivos.

Modelo relacional

Es el modelo más primitivo de análisis. Es un modelo cualitativo en el que el juicio del analista es el componente más importante. El modelo relacional no tiene, por lo general, una metodología estructurada y genérica; cada entidad aplica las relaciones o ratios que considera relevantes para definir su relación con el cliente y que serán de utilidad para determinar la capacidad de pago de prestatario para el crédito solicitado. Aun cuando cada entidad genera su propio modelo relacional, los procesos de análisis y ratios utilizadas, son comunes a la mayoría de ellas; si bien, la prelación entre las distintas relaciones dependerá de la experiencia, intuición y forma de actuar particular de cada prestamista.

El proceso de análisis es simple: se comparan las cifras del cliente con los movimientos que el mismo tiene en el banco. No existen elementos externos y objetivos de comparación de los atributos analizados del prestatario, llegando a carecerse de una medida de comparación referencial para la toma de decisiones.

El modelo no es predictivo, pues la información que se obtiene del deudor es siempre información histórica y los resultados del sistema de análisis se limitan a confirmar las situaciones ciertas presentadas.

⁵ Según (Quesada, et al. 2000), originados esencialmente por la asimetría de la información de los flujos de información entre las partes del contrato.

Modelo clásico de las cinco “C”

Este modelo toma el nombre de las iniciales inglesas de los conceptos que valora. Se trata de un modelo cualitativo que analiza para cada cliente de forma individual la moralidad del prestatario (*character*), la capacidad de pago (*capacity*), el patrimonio (*capital*), las garantías (*collateral*) y las condiciones aplicadas (*conditions*). La valoración de los diferentes elementos se realiza de una forma totalmente subjetiva; por lo tanto, un resultado óptimo dependerá de la experiencia e intuición del evaluador del riesgo.

El modelo clásico se emplea fundamentalmente para el análisis de prestatarios, personas físicas y pequeñas empresas, en las que la información contable no tiene gran relevancia. Para empresas con un nivel de actividad económica más complejo y con ámbitos de actuación extensos, se presentan graves carencias. El conocimiento y la intuición del analista no son suficientes para resolver las dudas que una corporación puede presentar sobre su capacidad de reembolso de una operación de crédito.

El modelo económico-financiero

El modelo económico-financiero es una evolución del modelo clásico de las cinco “C” con aportaciones del básico modelo relacional. Se aplica a empresas cuya información contable tenga fiabilidad, pues está basado en la información financiera y del entorno económico de la empresa. Los resultados del análisis económico financiero de la empresa se comparan con las empresas de similar actividad, obteniendo así información acerca de la tendencia de la empresa en relación con el sector económico al que pertenece.

El análisis económico-financiero avanza más en el conocimiento de la situación pasada de una empresa, tratando no sólo de describir situaciones históricas sino de buscarle la justificación a las mismas. La proyección de la situación futura valora más criterios que en modelos anteriores, al considerar elementos de gestión, de entorno e históricos, como determinantes de la capacidad de pago de la empresa durante la vida de la operación.

La limitación del modelo está en el horizonte temporal con el que habitualmente se trabaja (tres años) y que puede llevar a conclusiones erróneas sobre la capacidad de pago de la empresa en un período de tiempo medio o largo. La posibilidad de ampliar el horizonte de análisis a un plazo superior, no resuelve el problema de la subjetividad en la valoración de la situación futura, y sí hace peligrar la eficacia de la toma de decisiones, ralentizando el proceso sin que existan garantías de una mayor exactitud en los pronósticos.

Credit scoring

Mediante la aplicación de técnicas estadísticas se intentó automatizar el tratamiento de las diferentes variables que los analistas consideraban en el estudio de los riesgos de crédito. De hecho, el comportamiento de los analistas para riesgos con similares tipologías seguía un mismo esquema en el que la intuición y experiencia del experto otorgaban más peso a determinadas condiciones de una contraparte. El método de análisis de riesgo (*credit scoring*) modeliza esta experiencia y permite obtener probabilidades de morosidad para cada acreditado.

Existen diferentes modelos basados en los ratios de las empresas y compañías y su comparación sectorial; la selección de los ratios significativos se realiza, mediante el *análisis discriminante multivariable* realizado sobre los datos de empresas “buenas” y “malas”.

De forma general, se obtiene la siguiente función discriminante:

$$P = \alpha + \sum \beta_i x_i$$

Siendo β_i los coeficientes que expresan el significado e implicancia del variable explicatorio x_i , respecto a la función P . O en algunos casos, en el que se estima la probabilidad de que la entidad presente una situación crítica mediante

el uso de una función logit: $P = \frac{1}{1 + e^{-1}}$

La aplicación de la función obtenida a los valores de una empresa dará una puntuación (*score*) que diferenciará a la empresa del resto. El valor obtenido determinará la probabilidad de impago de la firma.

Este modelo interpreta la información ocurrida en el pasado, para predecir el comportamiento de pago futuro. El sistema puede quedar obsoleto si no se realiza un constante análisis de la cartera en vigor, a fin de detectar las modificaciones en el comportamiento de pago de los acreditados, bien por cambio de peso de las variables personales como de las variables macroeconómicas incorporadas. Una adecuada actualización del modelo mediante ajustes de las ponderaciones de cada una de las características valoradas permitirá un comportamiento eficiente del mismo como predictor del comportamiento de pago de las contrapartes analizadas. Este reajuste no eliminará las pérdidas que se produzcan por desajustes entre la probabilidad de mora que el modelo otorgue y la realidad de la cartera; pero evitará su obsolescencia. La capacidad predictiva de estos modelos de scoring se limita para aquellas contrapartes con características similares a las de la muestra utilizada en la asignación de puntos a las variables.

El modelo es totalmente estático y puede llegar a presentar problemas de correlación entre las variables. El solo hecho de una evaluación de la historia de una entidad introduce una exigencia de constante actualización, para evitar la falta de coherencia en su carácter predictivo. La predicción es realizada basándose en un modelo lineal cuando la realidad generalmente podría no admitir tal linealidad de los parámetros. En los casos en que la solvencia de la empresa depende de los flujos futuros, los modelos de scoring se muestran totalmente inoperantes. Otro problema en la aplicación de estos modelos radica en correlacionar las causas de los impagos de los créditos con valores exclusivamente de los balances financieros generales de las compañías.

Rating

Mientras que los sistemas de *scoring* analizan las variables para catalogar al cliente frente al resto de acreditados de una cartera indicando una puntuación (*score*) que permite conocer la probabilidad de pago de la contraparte; los sistemas de *rating* analizan las variables que se estiman relevantes como descriptores de la morosidad, mediante métodos empíricos, descriptores de la probabilidad de mora con el fin de

clasificar al cliente en una escala previamente definida a la que hay asociada diferentes comportamientos frente a la probabilidad de impago.

El modelo *rating* para análisis de riesgo de crédito se basa en un seguimiento continuo de la contraparte y en el alto volumen de información que se maneja para llegar a la calificación final de la firma. Resulta esencial el trabajo de analistas expertos, con experiencia en el sector económico y ámbito geográfico en el que opera la compañía.

Con estos sistemas consiguen tener diferenciados los clientes que son mejores de los peores y conocer la evolución de la situación de los mismos en el tiempo. Esto permite una mejor gestión del riesgo que el resto de los métodos de valoración del riesgo de crédito, pues permite hacer seguimiento de los clientes en el tiempo, compararlos entre sí y valorar a una entidad empresarial con la cual no se tiene relación previa.

El proceso de establecimiento de sistema de *rating* es costoso y lento, y las calificaciones individuales de los clientes obligan a tener amplia información, no sólo de parámetros financieros sino de negocio, en los casos del *rating* más avanzados se tienen en cuenta los siguientes tipos de variables de la empresa:

- Datos financieros: obtenidos del balance financiero general y del estado de resultados de la empresa.
- Datos internos no financieros (de carácter cualitativo): referencias a la estructura comercial, de personal y directiva, cuotas de mercado, etcétera.
- Información externa sobre comportamientos de pago, niveles de endeudamiento, etcétera.

Para hacer eficientes estos métodos de análisis, la ponderación de las variables de negocio y financieras ha de ser lo más objetiva posible evitando cualquier manipulación discrecional del evaluador del riesgo de crédito, y su peso en el *rating* final de la contraparte debe venir marcada por la influencia que este factor tiene en la probabilidad de insolvencia del cliente. La valoración objetiva de las variables indicadas y los pesos de las mismas en el *rating* final se obtiene por el análisis en

profundidad de las carteras mediante métodos estadísticos, a fin de determinar las variables explicativas de la morosidad y su peso en la misma.

2.2.3. Principales razones financieros para el análisis y gestión del riesgo

Una razón o ratio financiero, representa una relación entre magnitudes expresadas en unidades monetarias procedentes del balance financiero general y del estado de resultado, que nos describe la situación financiera de un negocio. Los ratios son punto de partida para cualquier tipo de análisis cuantitativo en la gestión de riesgo. Debe tenerse en cuenta que cualquier de estos representa una fotografía en un instante de tiempo dada, por ende su carácter descriptivo deberá tomarse en consideración para cualquier valoración prospectiva.

Clasificación de las razones financieras:

Ratios de solvencia y/o liquidez: La liquidez de una empresa se juzga por su capacidad para satisfacer sus necesidades a corto plazo a medida que estas se venzan. Las medidas básicas de la liquidez total de la empresa son:

- Razón circulante o índice de solvencia: Este índice se calcula dividiendo los activos circulantes entre los pasivos circulantes.
- Prueba ácida: Se calcula deduciendo los inventarios de los activos circulantes y dividiendo el remanente entre los pasivos circulantes.
- Prueba amarga: Esta razón se utiliza para verificar la liquidez a muy corto plazo, es decir la liquidez disponible (efectiva) en un momento dado.
- Capital de trabajo neto: este índice se calcula deduciendo su pasivo circulante de su activo circulante.

Ratios de liquidez a largo plazo: Se define también como grado de apalancamiento financiero. Indica el monto de dinero de terceros que se utilizan en el esfuerzo para generar utilidades. Se consideran en este grupo fundamentalmente las siguientes razones:

- Razón de endeudamiento: El apalancamiento financiero se mide normalmente como el ratio de la deuda a largo plazo sobre el capital total a largo plazo.

- Razón pasivo a capital: Esta razón indica la relación entre los fondos a largo plazo que suministran los acreedores y los que aportan los dueños de la empresa.
- Razón pasivo a capitalización total: Sirve para calcular el porcentaje de los fondos a largo plazo que suministran los acreedores.

Ratios de liquidez específica (actividad): Miden la liquidez de cuentas circulantes muy específicas o miden la eficiencia, eficacia o intensidad con que se emplean los activos para generar ventas. Se definen en gran medida por:

- Rotación del inventario: Significa cuántas veces es recuperado el efectivo invertido en el inventario en un período de tiempo determinado y la rapidez con que estos inventarios se convierten en cuentas por cobrar o en efectivo.
- Rotación de cuentas por cobrar: Significa cuántas veces en un determinado tiempo se convierte en efectivo toda la inversión en cuentas por cobrar.
- Rotación de cuentas por pagar: Significa el número de veces que las cuentas por pagar se convierten en efectivo en el curso del año.

Ratios de rentabilidad: Relaciona los rendimientos de la empresa con las ventas, los activos o el capital. Mide la eficiencia de la empresa y la eficacia en el desempeño de la administración. Son muy importantes para garantizar la sobrevivencia de la entidad analizada.

- Margen de utilidades en operación: Esta razón representa lo que a menudo se denominan utilidades puras que gana la empresa en el valor de cada venta.
- Margen neto de utilidad: Muestra la utilidad obtenida por cada peso de venta.
- Rendimiento sobre los activos totales: Determina la efectividad total de la administración para producir utilidades con los activos disponibles.
- Rendimiento sobre el capital: (Du Pont ampliado): Expresa la eficiencia en la utilización de la inversión de los dueños de la empresa, teniendo presente el tipo de financiamiento utilizado y su costo o el grado de apalancamiento financiero.
- Rotación de los Activos Totales: Este índice indica la eficiencia con que la empresa puede utilizar sus activos para generar ventas.
- Rotación de los activos fijos: Mide la efectividad de los activos fijos o el por ciento de la capacidad de utilización de estos.

La selección de unas u otras razones a emplear en el análisis dependen del analista y las situaciones específicas que se le presenten y se sugiere aplicar los instrumentos estadísticos ya expuestos para determinar aquellas que tengan más incidencia en el problema.

Es plausible utilizar otros datos, además de las razones financieras que incluyan entre otros: los juicios de valor, percepciones de los decisores, clasificaciones apriorísticas; lo cual ofrezca finalmente un panorama completamente abarcador del estado y fortaleza que posea una empresa cliente sometida a un criterio valorativo.

CAPITULO 3

Capítulo 3. Aplicación de las Redes Neuronales Artificiales en el análisis del riesgo crediticio

Una de las principales tendencias de la economía contemporánea es la interconexión profunda de las economías y por ende de los procesos productivos, comerciales y financieros. Evidentemente bajo estas condiciones, se complejizan cada vez más las gestiones de crédito sistemáticamente, lo que hace que las decisiones en este campo se tornen torpes incluso en el corto plazo. Por eso cobra importancia el surgimiento y la implementación de nuevas técnicas para agilizar dichos procesos, no solo desde el punto de vista de los acreedores y deudores, sino de la economía en general. Los bancos como instituciones especializadas y mayormente implicados en el tema, deben contar con sofisticados sistemas que sean capaces de evitar cualquier tipo de irregularidad mientras que entidades como empresas productivas o de servicio deben preocuparse en tener opciones de acceder a créditos para garantizar la ininterrupción de sus actividades.

Estos son los aspectos fundamentales que motivan la realización de una propuesta de aplicación de las RNA en la inversión y gestión de créditos, específicamente en el análisis del riesgo crediticio.

3.1. Propuesta de un procedimiento metodológico de aplicación de las RNA en el análisis del riesgo crediticio

En la realización de una investigación del universo empresarial (clientes de entidades financiero crediticias), es preciso determinar aquellos datos que servirán de punto de partida, para el diagnóstico y caracterización de las condiciones de liquidez y solvencia que regirán la conducta de las entidades susceptibles de recibir determinada financiación.

Para la aplicación de las RNA en un problema de tanta complejidad como lo es la gestión del riesgo crediticio por instituciones bancarias, este trabajo propone una propuesta de procedimiento metodológico de seis pasos que de inmediato se pasa a detallar.

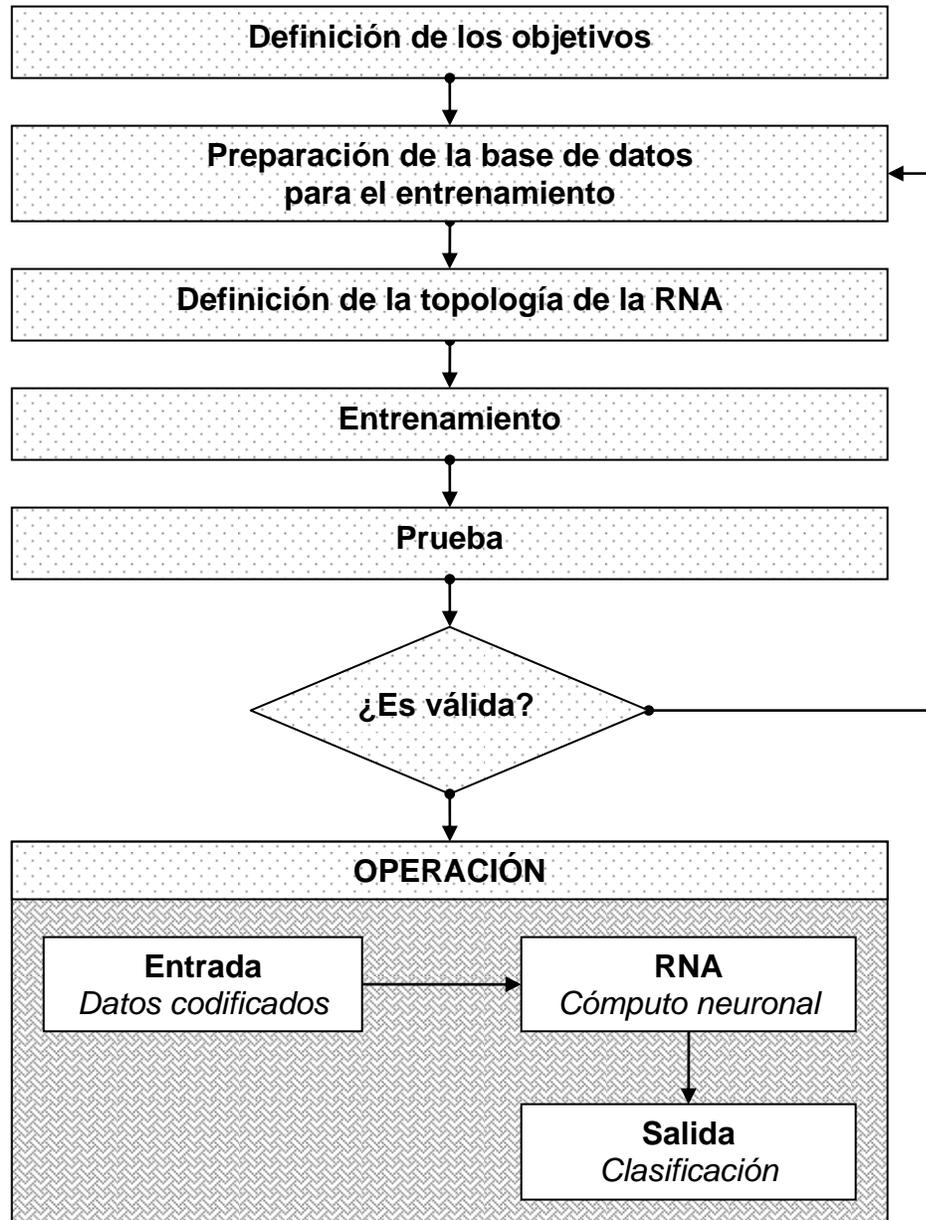


Figura 3.1. Procedimiento metodológico de aplicación de las RNA en el análisis del riesgo crediticio
Fuente: Elaboración propia

3.1.1. Definición de los objetivos

En este primer paso, se definirán los objetivos fundamentales que se espera a alcanzar a través de los criterios decisionales.

3.1.2. Preparación de la base de datos para el entrenamiento

En la *Preparación de la base de datos para el entrenamiento* deben ser tomados en consideración los siguientes aspectos que a continuación se detallan:

- Selección de las variables explicativas (estas pueden ser referentes razones, criterios de clasificación ó variables cualitativas).
 - + Definir las variables de importancia para la caracterización del problema definido.
 - + Seleccionar las variables más relevantes.
 - + Encontrar las fuentes de datos necesarios.
- Preparación y codificación de los datos.

3.1.3. Definición de la topología

La *definición de la topología de la RNA* depende parcialmente de la base de datos definida en el paso anterior. Los aspectos a considerar son los siguientes:

- Tipo de red
- Número de neuronas en la capa de entrada y de salida (según la codificación de datos realizada).
- Números de capas ocultas y neuronas necesarias.
- Tipo de neuronas
- Reglas de aprendizaje

3.1.4. Entrenamiento

Las decisiones concernientes al proceso de entrenamiento son:

- Definición del número ciclos de aprendizaje
- Determinación de la ponderación inicial empleada
- Establecimiento de la condición de detención del proceso de aprendizaje

El proceso de entrenamiento de la RNA se realizará dependiendo de las características y requerimientos del *software* utilizado para la simular la RNA.

3.1.5. Prueba

En este paso, se procesarán los patrones de prueba que constituirán la entrada habitual de la RNA, analizándose de esta manera las prestaciones de la red. Se volvería a paso 3.1.2 si los comportamientos de la RNA no satisficiesen los criterios decisionales establecidos en el paso 3.1.1.

3.1.6. Operación

Una vez terminado el entrenamiento, la RNA estará lista para clasificar los clientes nuevos simulando los datos de los mismos como entrada (sujetos a la misma codificación en el paso 3.1.2).

3.2. Caso de estudio

Para la validación de este procedimiento metodológico se ha empleado una base de datos, que representa una evaluación del crédito de clientes de instituciones financiero-crediticias. Véase (Quinlan 1987;1992). A los fines de lograr un entendimiento de los procesos, y aún cuando se carezca de los descriptivos suficientes de cada elemento de los clientes considerados en este estudio, se valoró oportuno el empleo del mismo en este trabajo para mostrar la viabilidad de esta aplicación instrumental.

Para la creación y simulación de las RNA, se utilizó el *software* comercial *Matlab*® en su versión 7.0, debido a la disposición de instrumentos profesionales y la facilidad del uso que proporciona este para esta investigación. La pantalla de trabajo principal de este programa se muestra en el anexo 1.

Definición de los objetivos

El objetivo principal de este caso de estudio fue: *determinar el diseño e una RNA que puede clasificar exactamente los clientes aspirantes al crédito en “buenos/malos” a partir de un conjunto de datos propios.*

Preparación de la base de datos para el entrenamiento

Debido a que los clientes que aspiran al otorgamiento de un crédito exigen un trato confidencial por parte de las instituciones financieras, quedó omitida en este estudio de caso, la descripción económica financiera de cada uno de los atributos. Se utilizó un conjunto de datos publicado en Internet⁶, caracterizado como sigue en la tabla:

Número de casos (clientes)	690
Datos faltantes	37
Clases	2 (<i>bueno, malo</i>)
Distribución de clases	307 (44.5%) <i>buenas</i> 383 (55.5%) <i>malas</i>
Número de atributos	15
- continuos	6
- binarios	4
- ordenados	5

Tabla 3.1. Resumen de la base de datos usada

Fuente: Elaboración propia

A la mayoría de los casos que tienen “datos faltantes”, le faltan datos en más de un atributo, algunos ni siquiera tienen clasificación definida, por lo que resultó conveniente eliminar los mismos. La base de datos finalmente queda con un total de 653 casos.

Fueron codificados los *atributos continuos* mediante una neurona (real). Los *atributos binarios* también fueron codificados por medio de una neurona (binaria).

A los *atributos ordenados* se les trató como sigue; ya que dependiendo de los diferentes valores que los mismos podían tomar, el número de neuronas utilizadas en la capa de entrada variaba. Fueron codificados cada uno de los posibles valores en una neurona; por ejemplo si hay tres valores posibles, se necesita de tres neuronas. (Véase anexo 2).

Existe una polémica entre distintos autores, relativa a la multicolinealidad y en general a la relación entre los componentes de los vectores de entrada. Algunos

⁶Quinlan, J. R. 1992. "C4.5: Programs for Machine Learning." *Morgan Kaufmann*.
<ftp://ftp.ics.uci.edu/pub/machine-learning-databases/credit-screening/>

indican que se pueden presentar graves problemas, en cuanto a tiempo de computación y memorización de la Red, además de la necesidad de disponer de series más largas: Estos autores, propugnan reducir el número de variables de entrada, cuando se presenten estas circunstancias, bien eliminando directamente una de cada dos que presenten una elevada correlación, o de lo contrario utilizando el *Análisis de Componentes Principales*⁷.

Por su parte otros autores, creen que los problemas son de índole menor y que en cualquier caso, es mejor utilizar todas las variables disponibles, pues al no perderse información, si bien el tiempo de computación puede aumentar, el error cometido será más pequeño.

En esta investigación, se dispuso una base de datos relativamente reducida en cuanto a su tamaño, por lo que se decidió aplicar el *Análisis de Componentes Principales* para eliminar la correlación entre las variables de entrada.

Primero los datos fueron normalizados para que tengan media cero y desviación típica uno, luego se aplicó el análisis de Componentes Principales mediante las siguientes sintaxis de Matlab[®], con *min_frac=0.001*:

```
>> [pn,meanp,stdp,tn,meant,stdt] = prestd(p,t);
```

```
>> [ptrans,transMat] = prepca(pn,min_frac);
```

Siendo:

⁷ El objetivo del Análisis de Componentes Principales, ACP, es transformar el espacio de representación X en nuevo espacio Y de menor dimensión, en el que los datos no estén correlacionados.

La matriz de covarianza en ese espacio será diagonal. Con el método se trata de encontrar el nuevo conjunto de ejes ortogonales en el que la varianza de los datos sea máxima y el objetivo final es reducir la dimensionalidad del problema.

Los pasos que se siguieron en ACP son los siguientes:

- Se normalizan los vectores de entrada X haciendo que su media sea cero y su desviación estándar sea igual a 1.
- Se calcula la matriz de covarianza de los vectores ya normalizados Σ_X . En este paso se utilizan todos los vectores de entrada.
- Se calculan los valores característicos de Σ_X , los cuales se definirán como $\lambda_1, \lambda_2, \dots, \lambda_d$, donde $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$.
- Se calculan los vectores característicos $\Phi_1, \Phi_2, \dots, \Phi_d$ asociados a $\lambda_1, \lambda_2, \dots, \lambda_d$
- Se forma la matriz de transformación $W = [\Phi_1, \Phi_2, \dots, \Phi_d]$
- Se calculan los nuevos vectores Y con la siguiente ecuación $Y = W^T \cdot X$, donde W^T es la matriz transpuesta de W, y Y es la matriz que contiene los nuevos vectores disminuidos en dimensión.

- p -- Matriz de vectores de entrada
- pn -- Matriz de vectores de entrada normalizados
- t -- Matriz vector de salida
- tn -- Matriz de vector de salida (normalizado)
- meanp -- Matriz que contiene las medias de cada atributo
- meant -- Matriz que contiene la media de la salida
- min_frac – Contribución mínima a la variación total permitida
- transMat – Matriz de transformación
- ptrans – Data set transformado

Como resultado, de los 43 variables (según la codificación anterior), se quedaron 34 variables para la entrada de las RNA.

Para evitar el *sobreajuste*⁸ en el entrenamiento se utilizó el método de validación cruzada (*cross-validation*) introducido por (Cover 1969). Dicho método consiste en dividir los datos muestrales en dos partes; una parte se utiliza como conjunto de entrenamiento para determinar los parámetros del clasificador neuronal y la otra parte, llamada conjunto de validación, se utiliza para estimar el error de generalización, es decir, la tasa de clasificación incorrecta del clasificador con datos diferentes a los utilizados en el proceso de entrenamiento.

En todos los ensayos, fue dividido el conjunto de datos en dos subconjuntos, con la proporción 75% (para el entrenamiento) y 25% (para la validación), manteniendo una distribución similar de los candidatos (clientes) buenos y malos en cada subconjunto, (véase tabla 3.2).

Subconjunto	Número de casos	Distribución
Entrenamiento	490	224 (45.7%) buenos 266 (54.3%) malos
Validación	163	72 (44.2%) buenos 91 (55.8%) malos

Tabla 3.2. División de datos para el entrenamiento y la validación
Fuente: Elaboración propia

⁸ Estado en el que la RNA memoriza los casos del entrenamiento, pero no “aprende” a generalizar para los casos nuevos.

Definición de la topología

El tipo de RNA usada en todos los ensayos fue *Perceptron multicapa*. Con el algoritmo de aprendizaje *Resilient backpropagation*⁹.

Utilizando el procedimiento de codificación anterior, luego de aplicar el *Análisis de Componentes Principales*, 34 neuronas resultaron necesarias en calidad de *capa de entrada*.

La *capa de salida* tiene una sola neurona que ofrece una clasificación de "bueno/malo".

En términos teóricos, las RNA con dos capas ocultas pueden representar funciones con cualquier forma (Hornik, et al. 1990), (Gallant y White 1992); por tanto, no existe razón alguna (al menos con base teórica) para utilizar redes con más de dos capas ocultas. Por ello se optó en este trabajo por construir RNA de una y dos capas ocultas. Si se hubiese añadido capas adicionales en la topología de la RNA, se asumiría un mayor costo computacional, sin obtener a cambio mejoras razonables en la capacidad de clasificación de este modelo.

El performance de la RNA es sensible con el número de neuronas en la (las) capa (s) oculta (s), una cantidad reducida de neuronas puede causar la insuficiencia en la capacidad de generalizar de la RNA; por el contrario, el exceso de las mismas provocará el *sobreajuste* de la red, de este modo en esta investigación, se decidió usar diferentes cantidad de neuronas para evaluar el comportamiento de la red.

En todos los ensayos, la función *logaritmo sigmoideo* fue tomada como función de transferencia para las capas de ocultas, y *función línea*, para la capa de salida.

Teniendo en cuenta todo lo anterior, fue seleccionado un conjunto de 15 RNA con topologías diferentes, las que se muestran en la tabla 3.3.

⁹ Una variación del algoritmo *Backpropagation*, en este algoritmo, sólo el signo de la derivada es utilizado para sacar la dirección de la actualización de los pesos, la magnitud de la misma no se utiliza en la actualización. El incremento o decremento de los pesos viene dado por dos variables que van tomando diferentes valores según el estado del algoritmo. Esto permite que el algoritmo converja más rápidamente ya que no está sujeto al valor del gradiente, solo a su signo (dirección), que puede tomar valores muy pequeños reduciendo notablemente la velocidad de la evolución de los pesos. Véase Riedmiller, M y H. Braun. 1993. "A direct adaptive method for faster backpropagation learning: the RPROP algorithm." *Neural Networks*, 1, pp. 586-91.

Capítulo 3. Aplicación de las Redes Neuronales Artificiales en el análisis del riesgo crediticio

RNA	Algoritmo de aprendizaje	Topología
1.	<i>Resilient backpropagation</i>	34-10-1
2	<i>Resilient backpropagation</i>	34-20-1
3	<i>Resilient backpropagation</i>	34-30-1
4	<i>Resilient backpropagation</i>	34-40-1
5	<i>Resilient backpropagation</i>	34-50-1
6	<i>Resilient backpropagation</i>	34-10-1-1
7	<i>Resilient backpropagation</i>	34-20-1-1
8	<i>Resilient backpropagation</i>	34-30-1-1
9	<i>Resilient backpropagation</i>	34-40-1-1
10	<i>Resilient backpropagation</i>	34-50-1-1
11	<i>Resilient backpropagation</i>	34-10-10-1
12	<i>Resilient backpropagation</i>	34-20-10-1
13	<i>Resilient backpropagation</i>	34-30-10-1
14	<i>Resilient backpropagation</i>	34-40-10-1
15	<i>Resilient backpropagation</i>	34-50-10-1

Tabla 3.3. Topología de las RNA elegidas para los ensayos

Fuente: Elaboración propia

La sintaxis de Matlab para crear estas RNA es la siguiente:

```
>> net = newff(minmax(ptr),[CAP1,CAP2,CAP3] ,{FT1,FT2,FT3},FE);
```

Siendo:

minmax(ptr) -- Matriz de valores máximos y mínimos de la entrada

CAP1 -- Tamaño de la capa oculta número 1

CAP2 -- Tamaño de la segunda capa oculta (este se omite para las redes que tienen solo una capa oculta)

CAP3 -- Tamaño de la capa salida, siempre toma valor 1 en esta investigación

FT1 -- Función de transferencia para la capa oculta 1 ("*logsig*" en este caso)

FT2 -- Función de transferencia para la segunda capa oculta ("*logsig*" en este caso)

FT3, -- Función de transferencia para la capa salida ("*purelin*" en este caso)

FE -- Función de entrenamiento ("*trainrp*" en este caso)

Entrenamiento

El aprendizaje se detendría cuando se cumpliera al menos una de las siguientes condiciones:

- Número máximo de 5000 iteraciones:
`>> net.trainParam.epochs=5000;`
- El error cuadrático medio MSE¹⁰ es inferior a 0.01:
`>> net.trainParam.goal=1e-2;`
- El error de la validación crece.

La iniciación de los pesos se realizó usando la función por defecto de Matlab.

```
>> net=init(net);
```

Las sintaxis de Matlab para entrenar la red:

```
>> [net,tr]=train(net,ptr,ttr,[],[],val);
```

Siendo:

- net -- La RNA creada en el paso anterior
- ptr -- La matriz de datos de entrenamiento
- ttr -- La matriz de clasificación deseado
- val -- Subconjunto de datos de validación
- tr -- Registro de cada iteración del entrenamiento

Prueba

Para cada topología seleccionada, se realizaron 500 ensayos. Luego se simularon las RNA con todos los datos (653 datos) con la siguiente sintaxis:

```
>> an = sim(net,ptrans);  
>> a = poststd(an,meant,stdt);
```

Los resultados simulados fueron comparados con los datos reales de la base de datos con objetivo de obtener el rendimiento entre las RNA. (Véase anexo 3, 4).

En resumen, se puede observar en la tabla siguiente:

¹⁰ Error cuadrático medio (MSE): Muestra el promedio de los errores al cuadrado. Mide la diferencia entre los valores estimados en la salida de la RNA con los valores deseados.

RNA	Topología	Número de iteración	Exactitud
1	34-10-1	10	92,0%
2	34-20-1	35	92,6%
3	34-30-1	24	93,3%
4	34-40-1	35	94,0%
5	34-50-1	31	93,3%
6	34-10-1-1	42	92,8%
7	34-20-1-1	31	94,0%
8	34-30-1-1	26	93,6%
9	34-40-1-1	23	93,3%
10	34-50-1-1	29	93,0%
11	34-10-10-1	22	93,0%
12	34-20-10-1	19	92,8%
13	34-30-10-1	21	93,3%
14	34-40-10-1	18	93,6%
15	34-50-10-1	21	94,5%

Tabla 3.4. Resumen de los resultados obtenidos
Fuente: Elaboración propia

El objetivo de este estudio de caso se cumplió con la RNA número 15 que ofreció el mejor rendimiento (94,5% de exactitud), lo cual representa el nivel más alto de clasificación correcta del universo de clientes a evaluar por este instrumento decisional. Cabe decir que ello estaría implicando un margen de error en materia de clasificación del 5.5 %.

Una correcta clasificación de los clientes en buenos y malos y una elevación de la exactitud en este proceso clasificador, podrían significar una disminución del costo económico asociado a cualquier de los dos comportamientos erróneos siguientes:

- Clientes aceptados por ser clasificados “buenos” representando una cartera de préstamo incobrable, en caso de que realmente no cumplan criterios de solvencia demostrada.
- Clientes rechazados por ser clasificados “malos” representando un rendimiento dejado de obtener por el banco en términos de préstamos dejados de otorgar con la redituabilidad prometida.

CONCLUSIONES

Conclusiones

Vivir en un mundo de alta volatilidad y que se declara incapaz de predecir los acontecimientos futuros con credibilidad suficiente es un hecho a la orden del día. El dinamismo e incertidumbre que impone la realidad económica actual, tanto a escala nacional como internacional, recaba del uso de modelos de gestión sofisticados y flexibles, cuyo desarrollo constituye uno de los principales retos del sector financiero. Junto al avance de otros instrumentos ya conocidos en la práctica y la literatura sobre el tema, las Redes Neuronales Artificiales se convierten en una alternativa viable y necesaria.

- Las RNA nacen de la imitación del modelo neuronal biológico, o sea el sistema neuronal que todo hombre posee, el cual le permite desarrollar aprendizaje y por ende evolucionar. Una RNA se puede definir como un *sistema de procesamiento que copia esquemáticamente la estructura neuronal del cerebro para tratar de reproducir sus capacidades, como por ejemplo, aprender de la experiencia a partir de las señales o datos del exterior, con el objetivo de construir sistemas de procesamiento de la información paralelos, distribuidos y adaptativos.*
- Para el “diseño arquitectónico de la red” (topología) deberá tenerse en cuenta el número de capas que la integren, el número de neuronas en cada capa, el tipo de conexión entre las neuronas, su función de activación y el algoritmo para entrenarse.
- En los últimos años, la teoría de RNA ha aportado valiosas contribuciones en el campo de la economía y las finanzas, gracias a sus capacidades de “aprender de la experiencia”, lograr la generalización de casos anteriores a nuevos casos, de extraer características esenciales a partir de entradas que representan información irrelevante.
- Entre los problemas que la práctica de las instituciones financieras demanda del uso de las RNA están: la necesidad de lograr una clasificación crediticia, la aprobación de créditos, la predicción del comportamiento de nuevos clientes, la selección de buenas clases de riesgo y la determinación del nivel de riesgo operacional.

- Las implicaciones del riesgo de crédito se definen como la probabilidad de no recuperar el monto original y los intereses derivados de un préstamo.
- Entre los modelos de gestión del riesgo de crédito se reconocen en la literatura los siguientes: el modelo relacional, el clásico de las cinco “C”, económico financiero, credit scoring y el rating.
- El empleo en cualquiera de los métodos anteriores demanda tanto de información cuantitativa tales como las razones financieras como datos de carácter cualitativo que incluyan los juicios de valor, percepciones de los decisores, clasificaciones apriorísticas entre otros.
- Para la aplicación de las RNA en un problema de tanta complejidad como lo es la gestión del riesgo crediticio por instituciones bancarias, este trabajo propone una propuesta de procedimiento metodológico que incluye como etapas fundamentales: la definición de los objetivos, la preparación de la base de datos para el entrenamiento, la definición de la topología de la red, el entrenamiento para la RNA, la fase de prueba del rendimiento, y la puesta de la red en operación.
- La validación del procedimiento metodológico con el empleo de las RNA desarrollado para una base de datos de 690 clientes ofreció evidencias de la viabilidad del uso de esta técnica como soporte para la toma de decisiones dentro de la inversión y gestión de créditos a clientes.

RECOMENDACIONES

Recomendaciones

- Tomando en cuenta la amplitud y diversidad de puntos de vista de los autores que abordan el problema de las RNA en su aplicación al objeto práctico de estudio resulta importante continuar profundizando desde la teoría y la validación práctica en la sistematización de este instrumento decisonal.
- Dada la urgencia en la utilización de las RNA en la gestión del crédito por parte de las instituciones financieras crediticias cubanas, resulta aconsejable recomendar la formalización de bases de datos homogéneas y suficientemente explícitas, que se adecuen a los requerimientos informacionales para la implementación del procedimiento metodológico propuesto en esta investigación.
- Se recomienda la aplicación de esta RNA en el problema objeto de estudio práctico, tomando en cuenta que se logra asegurar una disminución de los errores decisionales en términos de clasificación de clientes de los bancos y con ello minimizar los costos económicos sociales de recursos inmovilizados por préstamos otorgados inmerecidamente o créditos rechazados injustamente.
- Sería recomendable ampliar los criterios a tomar en cuenta en la conformación topológica de la red, para tener una visión más abarcadora del proceso decisonal estudiado.
- Incorporar el presente trabajo en calidad de documento monográfico a la literatura complementaria de los estudios de nivel de pregrado y de postgrado en las áreas de finanzas y de matemáticas aplicadas.

BIBLIOGRAFIA

Bibliografía

Aragón Torre, Alberto, J. María Calzada Arroyo, Alfredo García Güemes, y Joaquín Pacheco Bonrostro. 1997. "Aplicaciones de Redes Neuronales en economía." *ASEPUMA*, V.

Brunel, J. P. 2005. "Modelos de Redes Neuronales y el Precio del Cobre: Una Perspectiva Sorprendente." Universidad de Chile.

Cover, T. M. 1969. "Methodologies of Pattern Recognition." *Academic press*, pp. 111-32.

Gallant, A. R. y H. White. 1992. "On Learning the Derivatives of an Unknown Mapping with Multilayer Feedforward Networks." *Neural Networks*, 5, pp. 129-38.

Gondar, J. E. 2001. "Redes Neuronales Artificiales." *Data Mining Institute*.

Haykin, S. 1994. *Neural Networks*. New York: Macmillan College Publishing Company.

Hilera, J. R. y V. J. Martínez. 1994. "Redes Neuronales Artificiales. Fundamentos, Modelos y Aplicaciones." *Rama*.

Hornik, K., M. Stinchcombe, y H. White. 1990. "Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks." *Neural Networks*, 3, pp. 551-60.

Martin del Brio, B. y C. Serrano. 1995. *Self organizing Neural Networks: The Financial State Of Spanish Companies*.

Matich, D. 2001. "Redes Neuronales: Conceptos Básicos y Aplicaciones." *Cátedra: Informática Aplicada a la Ingeniería de Procesos – Orientación I*.

Palacios, F. 2003. "Herramientas en GNU/Linux para estudiantes universitarios."

Pérez, Rafael Bello. 1993. *Curso introductorio a las redes neuronales artificiales*. Santa Clara: Departamento de Ciencia de la Computación. Universidad Central de Las Villas.

Quesada, Joaquín del Águila, Francisco Joaquín Cortés García, Irene Fernández Ruiz, y Francisca Jesús García Moreno. 2000. *El riesgo en la industria bancaria. Una aproximación a Basilea II*. Barcelona: Instituto de Estudios Socioeconómicos de Cajamar.

Quinlan, J. R. 1987. "Simplifying decision trees." *Int J Man-Machine Studies*, 27, pp. 221-34.

Quinlan, J. R. 1992. "C4.5: Programs for Machine Learning." *Morgan Kaufmann*.

Ricote Gil, F. 2003. "Teoría de las Redes Neuronales para la Gerencia de Riesgos."

Riedmiller, M. y H. Braun. 1993. "A direct adaptive method for faster backpropagation learning: the RPROP algorithm." *Neural Networks*, 1, pp. 586-91.

Silva, J. L. 2005. "Predicción del rendimiento académico con redes neuronales." Universidad de Concepción.

Weston, J. Fred y E. F. Brigham. 1993. *Fundamentos de administración financiera*. Mexico: Editorial Mc Graw Hill.

ANEXOS

Anexos

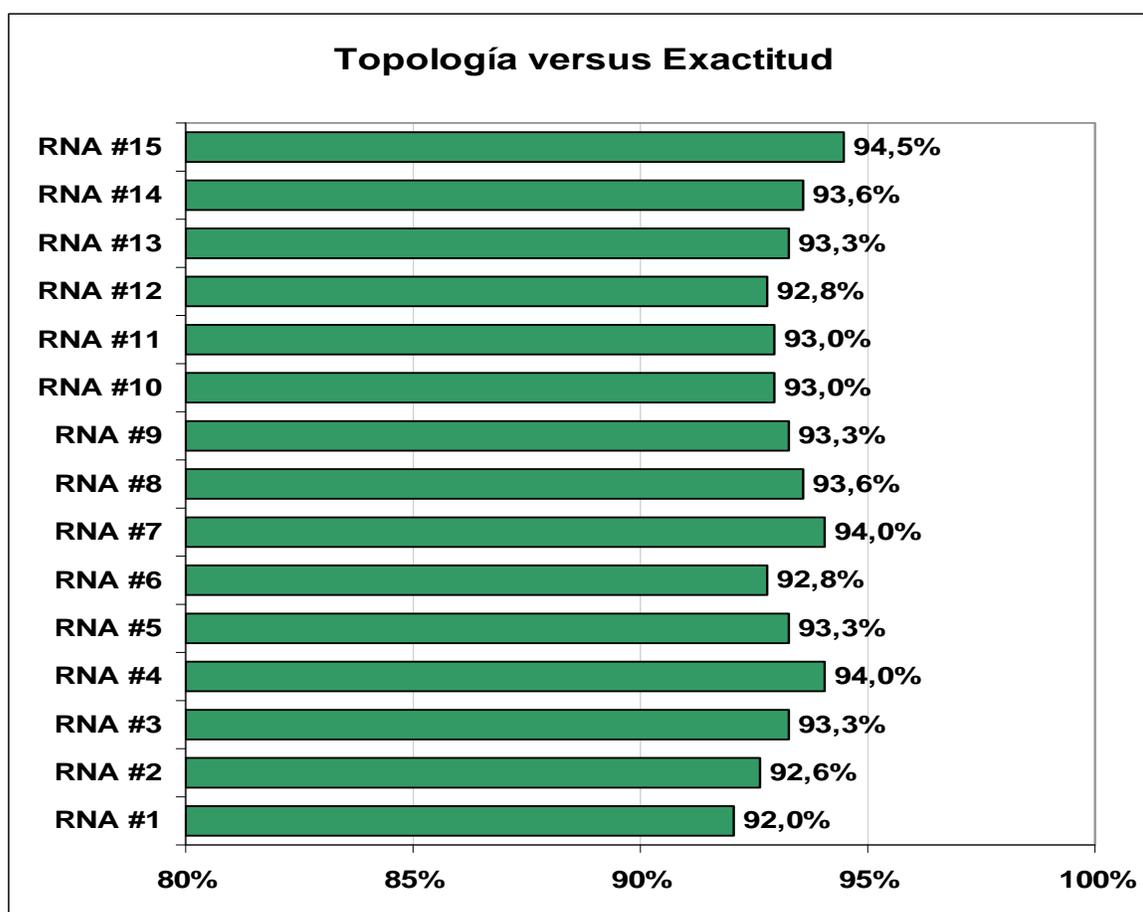
Anexo 1. Pantalla de Matlab® v7.0

The screenshot displays the MATLAB v7.0 environment. The **Workspace** window on the left lists variables such as Q, R, a, an, ans, b, data, itr, iitst, iival, m, meanp, meant, and net. The **Command Window** on the right shows the output of a command, including details about outputs, targets, biases, input weights, layer weights, functions, parameters, weight and bias values, and other user data. The **Command History** window at the bottom left shows the sequence of commands entered, including clearing variables and simulating a neural network. Annotations with arrows point to specific parts of the interface:

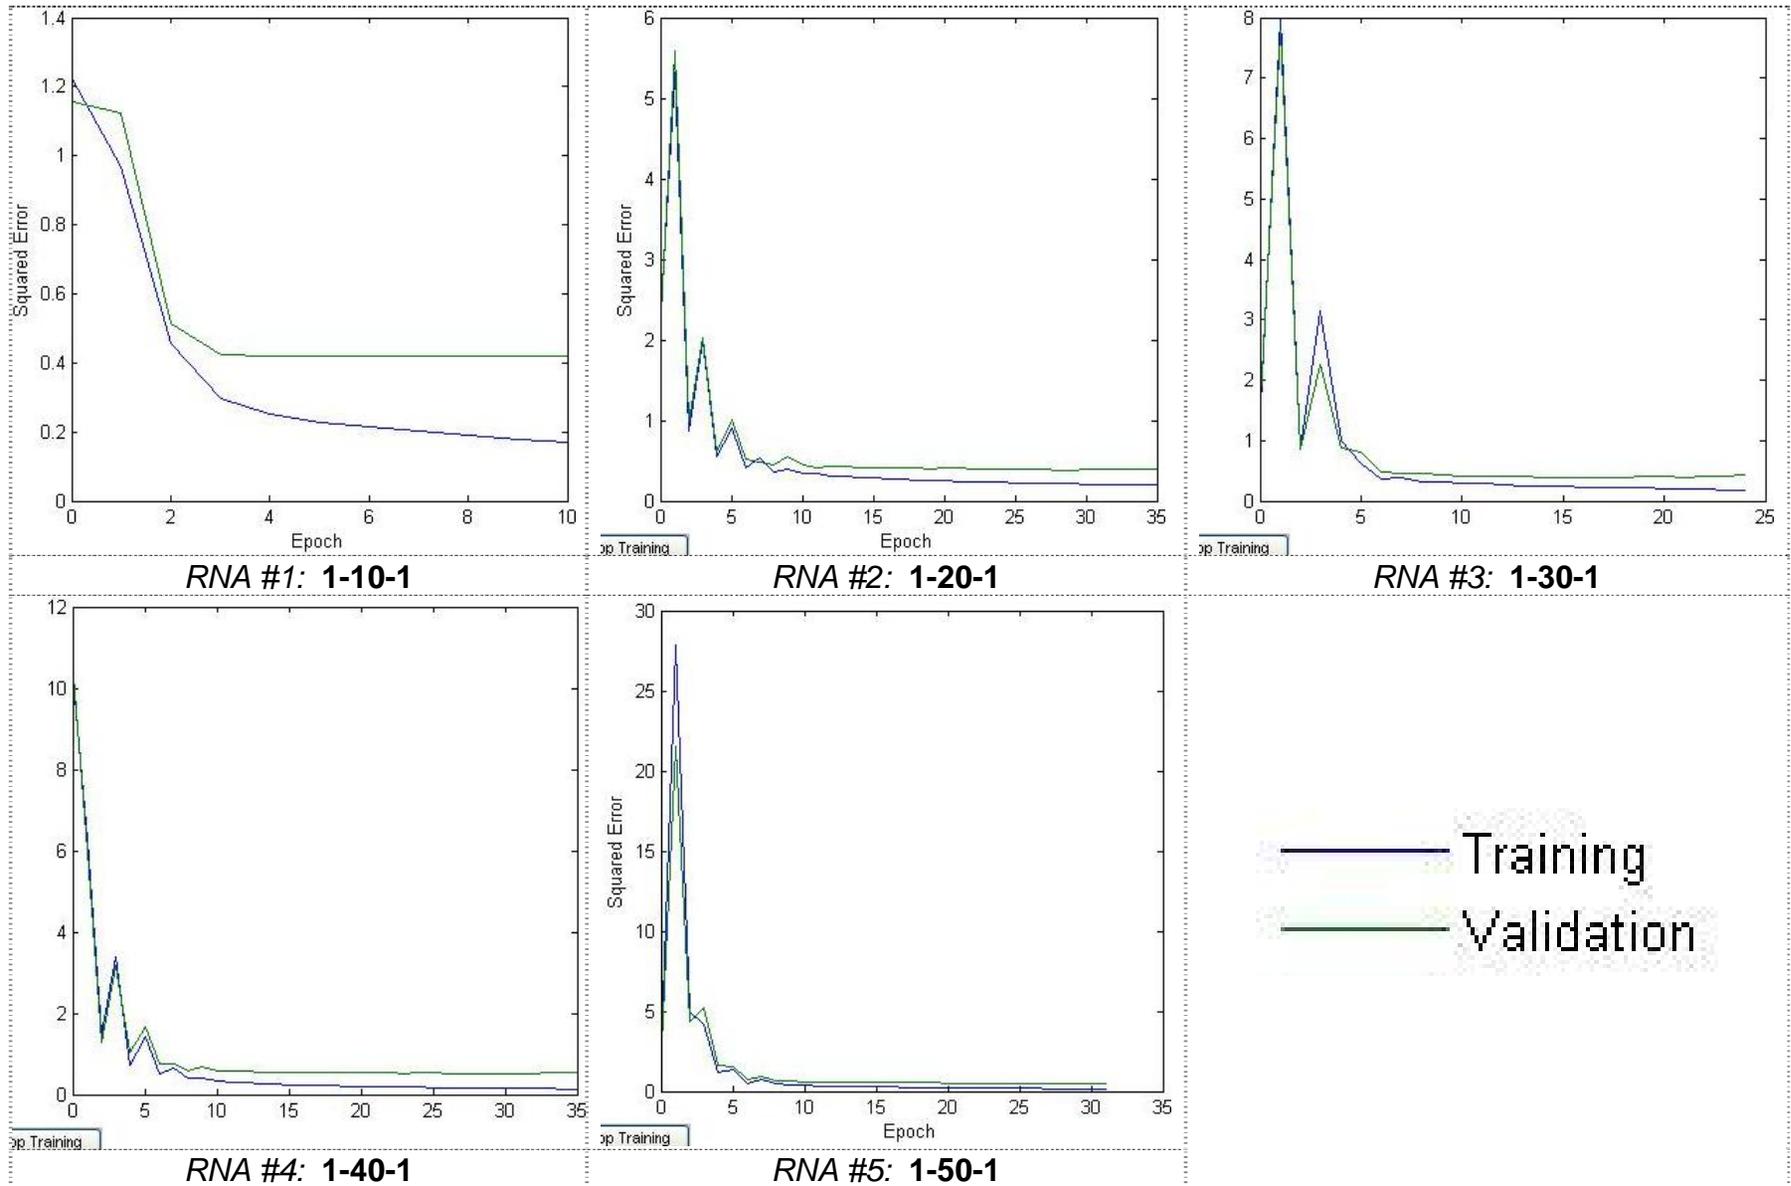
- Ventana de comandos**: Points to the Command Window.
- Espacio de trabajo**: Points to the Workspace window.
- Ventana de comandos históricos**: Points to the Command History window.
- Línea de comando**: Points to the Command Line at the bottom of the Command Window.

Anexo 3. Rendimiento de las Redes Neuronales Artificiales

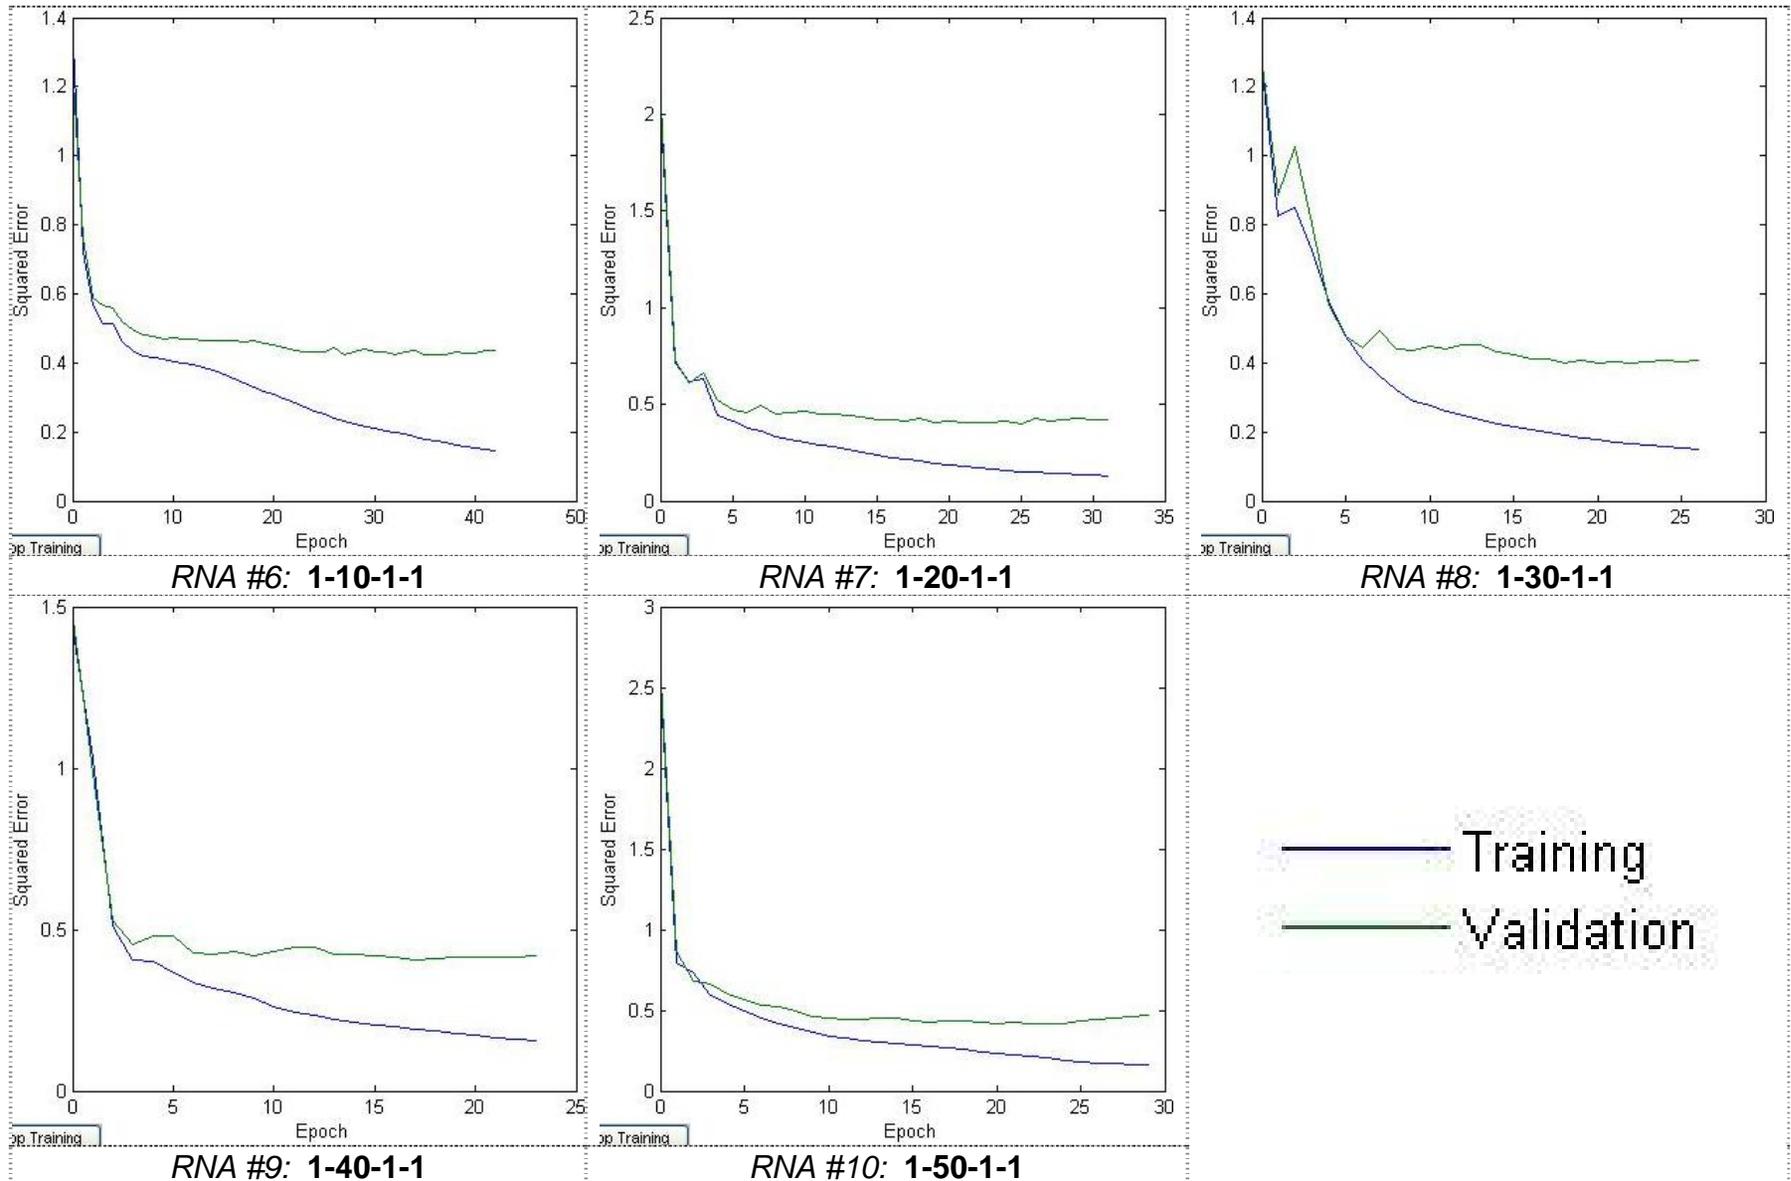
Nº	Topología	Entrenamiento	Número de iteraciones	R	Total casos	Número de casos mal clasificados	Exactitud
1	34-10-1	trainrp	10	0.8408	653	52	92.04%
2	34-20-1	trainrp	35	0.8635	653	48	92.65%
3	34-30-1	trainrp	24	0.8603	653	44	93.26%
4	34-40-1	trainrp	35	0.8695	653	39	94.03%
5	34-50-1	trainrp	31	0.8608	653	44	93.26%
6	34-10-1-1	trainrp	42	0.8743	653	47	92.80%
7	34-20-1-1	trainrp	31	0.8874	653	39	94.03%
8	34-30-1-1	trainrp	26	0.8764	653	42	93.57%
9	34-40-1-1	trainrp	23	0.8687	653	44	93.26%
10	34-50-1-1	trainrp	29	0.8630	653	46	92.96%
11	34-10-10-1	trainrp	22	0.8609	653	46	92.96%
12	34-20-10-1	trainrp	19	0.8701	653	47	92.80%
13	34-30-10-1	trainrp	21	0.8759	653	44	93.26%
14	34-40-10-1	trainrp	18	0.8699	653	42	93.57%
15	34-50-10-1	trainrp	21	0.8814	653	36	94.49%



Anexo 4. Evolución del *error cuadrado* en los procesos de entrenamiento y validación



Anexo 4. Evolución del *error cuadrado* en los procesos de entrenamiento y validación (continuación)



Anexo 4. Evolución del *error cuadrado* en los procesos de entrenamiento y validación (continuación)

