

SIMULACIÓN DE LAS CALIFICACIONES DE RATING DE LA AGENCIA S&P MEDIANTE REDES NEURONALES ARTIFICIALES Y RATIOS FINANCIEROS

Oscar García Fernández, m_ali_ogar@telefonica.net

Manuel Rodríguez López, marod@udc.es

Universidad de La Coruña

ABSTRACT

Tradicionalmente los *ratings* han sido asignados por expertos al servicio de agencias de calificación. En este estudio experimental se han utilizado los datos financieros de 126 empresas calificadas por Standar&Poor's para generar diferentes modelos de redes neuronales con el objetivo de obtener una herramienta de ayuda a la decisión de inversión tratando de simular las calificaciones asignadas por dicha agencia. Se experimentaron estructuras con una o varias capas ocultas y diferentes números de nodos estudiando la calificación en 9 categorías: AAA, AA, A, BBB, BB, B, CCC, CC, D y en tres categorías: Grado Inversión, Grado Especulativo y Grado de Impago. La precisión alcanzada es insuficiente para dar credibilidad a los resultados de la herramienta planteada y sugiere la necesidad de ampliar el estudio incorporando información cualitativa y de segmentación adicional a la información financiera tradicional.

Palabras Clave. Redes Neuronales, Calificación del riesgo de crédito (*Rating*), Problemas de Clasificación.

1. INTRODUCCIÓN

Las calificaciones crediticias (*ratings*) representan, según Verona Martel (2002) y López Pascual (1996), un indicador expresivo de la mayor o menor capacidad o probabilidad del pago en el tiempo estipulado tanto de los intereses como de la devolución del principal que toda deuda comporta, es decir, del riesgo crediticio que soporta el inversor que ha prestado sus fondos a la entidad que los ha recibido.

Para el segundo autor, las calificaciones deben ser el resultado de un estudio y análisis basado en opiniones imparciales, documentadas y profesionales realizadas por agencias especializadas. La calificación refleja la opinión de las agencias especializadas que las otorgan, considerando elementos de análisis cualitativo y cuantitativo, respecto a la solvencia de un deudor con respecto a una obligación específica, Verona Martel(2002).

Cada agencia de calificación tiene sus procedimientos, metodologías y criterios propios. [DALLAS (1993)]. El proceso de calificación de las empresas que realizan las agencias de calificación es complejo y recae fundamentalmente en la valoración que un equipo de expertos realiza de la situación de la empresa. La agencia Standard&Poor's, por ejemplo, basa su calificación en el resultado de sucesivas entrevistas con los directivos de la entidad calificada realizadas por analistas especialistas en el sector y país. A partir de la información obtenida se elabora un informe con una metodología uniforme, atendiendo a aspectos de sector, posición competitiva, estrategia, gestión, propiedad, resultados financieros pasados y expectativas futuras.

Toda la información resultante de esta labor de análisis se resume a través de una serie de símbolos y se hace pública para ser utilizada por los agentes del mercado financiero, Verona Martel(2002), presentando como características principales: ser un instrumento simple y sencillo que ayuda en la toma de decisiones de inversión; permitir que se pongan en contacto prestamistas y prestatarios muy alejados geográficamente e intentar hacer comparables entre sí los diferentes mercados e instrumentos de crédito. Sin embargo, a tenor de lo recogido en el trabajo del mismo autor, todas las agencias coinciden en afirmar que su calificación no es una recomendación para comprar, mantener o vender títulos. Es sólo una herramienta más que ayuda en la toma de decisiones de inversión.

1.1. OBJETIVOS DEL ESTUDIO.

Las agencias de calificación realizan calificaciones de empresas concretas, y por ejemplo, Standar&Poor's sólo emite su calificación para aquellas empresas que lo han solicitado previamente. Sin embargo, tal como se indica en el párrafo anterior, la opinión de las agencias de calificación sobre el riesgo crediticio es una herramienta muy útil a la hora de valorar el riesgo de crédito de las empresas, por lo que parece interesante disponer de una herramienta de calificación semejante a la opinión de las agencias para valorar aquellas empresas de las que, por distintos motivos, no existe su valoración o rating.

Ciertos autores, como Garavaglia(1991), Shaw et al. (1990) y Dutta et al.(1988), han intentado definir una aproximación al modelo empleado por las agencias de calificación que permita extrapolar de alguna manera sus resultados, proporcionando una nueva herramienta de análisis de riesgo. Sin embargo, los modelos que utilizan las agencias de rating están basados en la valoración de factores cuantitativos y cualitativos combinados en un proceso de agregación cuya formulación no es pública. Así, por ejemplo, la agencia Standar&Poor's edita una visión general de la metodología empleada para emitir sus calificaciones, haciendo una descripción de los criterios que valora: Riesgo del negocio, claves de éxito, factores de diversificación, consideraciones de tamaño de la empresa, evaluación de la gestión, detalles de la organización, calidad contable, política financiera y flexibilidad y ratios de situación. Corporate Ratings Criteria(2002). Esta información no contiene el detalle necesario para formular un modelo matemático que permita aprovechar el conocimiento

de las empresas de la agencia de calificación, debido, fundamentalmente, a la influencia de la experiencia de los expertos de la agencia para juzgar los factores cualitativos.

La valoración del riesgo crediticio de una empresa está condicionada por la complejidad del conjunto de datos financieros necesarios para tomar una decisión. Las dificultades para el decisor se resumen en las tres siguientes para Shaw et al. (1990):

1. Identificar los atributos o datos más relevantes, tanto cuantitativos como cualitativos, para caracterizar el estado financiero de las empresas.
2. Definir perfiles de empresas para cada clase de riesgo en función de esos atributos
3. Clasificar las empresas utilizando los datos de los dos pasos anteriores.

Estas tareas son muy semejantes a las realizadas en problemas de clasificación por reconocimiento de patrones.

Dutta et al.(1988) plantean el problema de clasificación como la asignación de cada caso de entrada (dentro de un conjunto de entradas dado), en función de los rasgos que lo definen, a una categoría de la serie de categorías predefinidas.

Debido a la complejidad de las relaciones que intervienen en la obtención de las calificaciones, las redes neuronales se presentan como una herramienta potencialmente más precisa que las herramientas estadísticas tradicionales, tal como se deduce de los trabajos de Garavaglia (1991), Shaw et al. (1990) y Dutta et al.(1988) en los que se han comparado los resultados de ambos métodos. Las redes neuronales son modelos adaptativos que buscan satisfacer objetivos, en línea con la teoría de la racionalidad limitada de Simon (2003), en lugar de buscar la optimización de la solución, utilizando algoritmos que inducen modelos a partir de ejemplos conocidos requiriendo menor cantidad de información a priori.

Obtener una herramienta con la habilidad de producir ratings equivalentes a los proporcionados por la Agencia Standard and Poor's para empresas que no han sido valoradas, por su tamaño y mercado, utilizando una red neuronal para inducir primeramente el modelo genérico y posteriormente aplicarlo a una muestra de empresas no calificadas es el objetivo final de este trabajo.

2. MODELO NEURONAL.

La red neuronal de tipo back-propagation es una de las tipologías más populares y utilizadas para resolver diferentes tipos de problemas. Esta red se basa en un procedimiento supervisado, es decir, la red construye el modelo utilizando ejemplos, con datos conocidos de entrada y su salida correspondiente, que se supone incorporan la información necesaria para obtener la relación que las une. [LEK et al. (2000)].

El algoritmo de esta red trata de reproducir la forma de una neurona biológica. Cada neurona o nodo de la red artificial puede tener varias entradas, pero sólo tiene una salida que puede estimular otras neuronas de la red. Las conexiones biológicas de las neuronas se simulan en la red por medio de unas interconexiones matemáticas a las que se les asigna un valor cuantitativo denominado peso. La conexión de la neurona i -ésima puede excitar a la neurona j -ésima si el peso de la conexión es positivo o puede inhibirla si el peso es negativo.

La arquitectura de esta red es del tipo feed-forward, es decir, las neuronas están colocadas en sucesivas capas y la información fluye de una capa a otra en una única dirección desde la capa de entrada hacia la de salida, atravesando la o las capas ocultas. Los nodos o neuronas de cada capa están conectados con todos los nodos de la capa siguiente, pero no hay conexiones laterales entre las neuronas de la misma capa. El número de nodos de entrada y de salida depende del número de entradas y salidas del problema estudiado.

La primera fase de la construcción del modelo es el entrenamiento: un conjunto de entradas/salidas objetivo se presenta a la red en sucesivas ocasiones. En cada ocasión la red proporciona una respuesta y con ella se calcula la diferencia con la respuesta objetivo. Esta diferencia será el error a partir del cual se modificarán los pesos de las interconexiones, iniciando el ajuste en la capa de salida y retrocediendo a través de las capas ocultas hasta la capa de entrada. Las modificaciones irán encaminadas a minimizar el error idealmente y, en la práctica, a obtener un nivel satisfactorio de error que evite oscilaciones y mínimos locales que afectarían negativamente al aprendizaje de la red.

Un punto crítico de esta fase, apuntado por el mismo autor, es el peligro de entrenar demasiado a la red con los ejemplos, ya que entonces la red aprende distinguiendo detalles específicos del conjunto de entrenamiento en lugar de modelar un problema genérico, perdiendo su capacidad de generalización.

Una vez finalizada la fase de entrenamiento, se realiza una realimentación de la red mediante la comprobación de los resultados obtenidos presentado a la red un nuevo conjunto de datos de entrada (no utilizados en la fase de entrenamiento) y comparando la salida que da la red trabajando sin supervisión con el dato de salida real para obtener una indicación del rendimiento del modelo neuronal.

Concluidas las fases anteriores la red está lista para recibir los datos del problema que se desea resolver.

3. DATOS PARA EL MODELO.

Standard and Poor's Corporation (S&P), es una de las mayores agencias mundialmente reconocida. Fue fundada en 1860 y actualmente pertenece al grupo McGraw-Hill. En 1923 comenzó a calificar la deuda de emisores corporativos y municipales.

S&P no publica las características concretas de su metodología de calificación, aunque sí distribuye libremente las características generales de los factores que influyen y del significado de sus calificaciones, que se muestran en la Tabla1. La elección de esta agencia como fuente de datos para realizar este estudio se debe a la disponibilidad de calificaciones públicas.

Tabla1. Calificaciones según la capacidad de pago a largo plazo.

| | TIPO | Definición |
|-------------------------------------|-------------|---|
| GRADO DE INVERSIÓN | AAA | Calidad crediticia óptima |
| | AA | Alta calidad crediticia. |
| | A | Buena calidad crediticia. |
| | BBB | Calidad crediticia satisfactoria. Existen tensiones en el L/P. Acontecimientos adversos pueden empeorar su capacidad de pago. |
| GRADO DE ESPECULACIÓN | BB | Calidad crediticia cuestionable. Futuro inseguro pero con capacidad actual. |
| | B | Calidad crediticia pobre/dudosa. Capacidad de hacer frente a las dudas a L/P es baja. |
| | CCC | Calidad crediticia muy pobre. Posibilidad actual de algún tipo de impagos |
| ESPECULACION CON ALTO RIESGO | CC | Calidad crediticia muy pobre. Alta probabilidad de algún tipo de impagos. |
| | C | En situación de insolvencia aunque pueden seguir realizándose algunos pagos. |
| | D | Default. Probabilidad de recobro <50% |

Fuente: Elaboración propia a partir de www.standardandpoors.com y www.cajamadrid.es

El punto de partida de la recopilación de datos fue la captura de las calificaciones para el total de las empresas por sector calificadas actualmente por S&P. Del total de las mismas, se seleccionaron inicialmente aquellas que desarrollan su actividad en el mercado de Estados Unidos, por la facilidad para disponer de los datos de sus cuentas anuales a partir de los informes exigidos por la Securities and exchange commission (SEC) para las primeras. El número total de compañías estadounidenses se muestra en la Tabla2.

Tabla2. Numero total de empresas calificadas por S&P por sector en Estados Unidos.

| SECTOR | TOTAL |
|----------------------------|--------------|
| Consumer Discretionary | 537 |
| Consumer Staples | 161 |
| Energy | 182 |
| Health Care | 196 |
| Industrial | 318 |
| Information Technology | 141 |
| Materials | 214 |
| Telecommunication services | 32 |
| Utilities | 353 |
| Total general | 2.134 |

Fuente: Elaboración propia a partir de www.standardandpoors.com

Fue necesario acudir al mercado estadounidense debido a que el número de entidades españolas calificadas era insuficiente para abarcar el abanico de tipos de calificaciones y tan pequeño que las fases de entrenamiento y verificación de la red estaban seriamente comprometidas. En la Tabla3 se muestra el resumen de las empresas españolas calificadas.

Tabla 3. Empresas españolas calificadas.

| EMPRESA | CALIFICACIÓN |
|---|--------------|
| Enagas S.A. | AA |
| Red Eléctrica de España S.A. | AA |
| Sociedad General de Aguas de Barcelona S.A. | AA |
| Altadis S.A. | A |
| Endesa S.A. | A |
| Gas Natural SDG, S.A. | A |
| Iberdrola S.A. | A |
| Repsol-YPF S.A. | BBB |
| Cemex España, S.A. | BBB |
| Unión Fenosa S.A. | BBB |
| Cableuropa S.A.U. | CCC |

Fuente: Elaboración propia a partir de www.standardandpoors.com

De las 2134 corporaciones estadounidenses, 37 no están calificadas actualmente. La distribución por categoría de rating de las 2097 empresas restantes se muestra en la Tabla4. Los indicadores complementarios que indican la posición relativa en cada categoría de calificación [+ , -] se han eliminado del estudio debido al elevado número de categorías necesarias resultantes y al escaso número de corporaciones en algunas de las categorías complementadas

Tabla 4. Numero de empresas estadounidenses por categoría de rating.

| CALIFICACIÓN | TOTAL | PORCENTAJE |
|----------------------|--------------|-------------|
| AAA | 20 | 1% |
| AA | 59 | 2,8% |
| A | 306 | 14,6% |
| BBB | 515 | 24,6% |
| BB | 492 | 23,5% |
| B | 600 | 28,6% |
| CCC | 79 | 3,8% |
| CC | 5 | 0,2% |
| D | 21 | 1% |
| Total general | 2.097 | 100% |

Fuente: Elaboración propia a partir de www.standardandpoors.com

Con la relación de empresas totales se seleccionaron aleatoriamente 10 empresas de cada categoría, para las cuales se buscó la información completa de resultados de las cuentas anuales [www.sec.gov] que permiten calcular las ratios financieras necesarias para las etapas posteriores del estudio.

Para la categoría de calificación “CC” el número de empresas disponibles no era suficiente. Esta categoría de Standar&Poor’s, se asemeja a la situación de Suspensión de Pagos proporcionada por la base de datos SABI de la empresa INFORMA, S.A.. Por lo que, para completar la cantidad de empresas necesarias, se utilizaron datos de empresas disponibles en la citada base de datos. En el momento de la búsqueda se encontraban 128 empresas en este estado con el último ejercicio disponible superior al 2002.

El conjunto de empresas se divide en dos subconjuntos, el primero para la etapa de entrenamiento y el segundo para la etapa de verificación, con la distribución indicada en la Tabla5.

Tabla5. Corporaciones seleccionadas por fase de desarrollo del modelo.

| CALIFICACIÓN | ENTRENAMIENTO | VERIFICACIÓN | TOTAL |
|----------------------|---------------|--------------|------------|
| AAA | 10 | 4 | 14 |
| AA | 10 | 4 | 14 |
| A | 10 | 4 | 14 |
| BBB | 10 | 4 | 14 |
| BB | 10 | 4 | 14 |
| B | 10 | 4 | 14 |
| CCC | 10 | 4 | 14 |
| CC | 10 | 4 | 14 |
| D | 10 | 4 | 14 |
| Total general | 90 | 36 | 126 |

De la cuenta de resultados anuales se obtiene una batería de datos que se muestra en el Anexo I.

4. DISEÑO Y ENTRENAMIENTO DEL MODELO.

4.1. Selección de Variables.

Los datos obtenidos permiten calcular multitud de ratios. El trabajo se estructuró partiendo de siete modelos para estudiar su comportamiento y seleccionar el mejor.

Hsu(2002) realizó una recopilación de los trabajos que han abordado este tema, concluyendo que el número de ratios puede ser reducido a un conjunto mínimo sin afectar a la precisión del resultado. Para contrastar esta hipótesis construimos los tres primeros modelos a partir de las ratios mostradas en la tabla 6, utilizadas por Surkan et al.(1992) para construir una herramienta basada en redes neuronales que permitía obtener las ratings de empresas a partir de sus datos financieros.

Tabla 6. Ratios utilizadas en los modelos 1 y 2.
(Fuente: Elaboración propia a partir de Surkan et al.(1992)).

| RATIO | DESCRIPCIÓN |
|-------|--|
| R1 | Pasivo/(Cash flow operativo+Activos) |
| R2 | Pasivo fijo/Fondos Propios+Pasivo Fijo |
| R3 | Ventas/Fondos Propios |
| R4 | Resultado Neto/Ventas |
| R5 | Resultado Explotacion/Consumos |
| R6 | Capital Circulante/Ventas |

Para construir los modelos 4 y 5 se utilizaron valores obtenidos directamente de la cuenta de resultados, sin realizar ningún cálculo sobre ellos. Los valores seleccionados se muestran en la Tabla 7.

Tabla 7. Variables financieras utilizadas en los modelos 3 y 4.
(Fuente: Elaboración propia)

| VARIABLE | DEFINICIÓN |
|----------|-----------------------|
| V1 | Tesorería |
| V2 | Existencias |
| V3 | Activo Circulante |
| V4 | Activo Fijo |
| V5 | Activo Total |
| V6 | Pasivo Circulante |
| V7 | Pasivo Exigible |
| V8 | Fondos Propios |
| V9 | Ventas |
| V10 | Consumos explotación |
| V11 | Resultado Explotacion |
| V12 | Resultado neto |
| V13 | Impuestos |
| V14 | Intereses |
| V15 | Cash flow |

Para construir los modelos restantes se calcularon las ratios más habituales en la literatura mostradas en la tabla 8.

Tabla 8. Ratios utilizados en los modelos 5, 6 y 7.(Fuente: Elaboración propia)

| RATIO | DESCRIPCIÓN |
|--------------|--|
| R1 | Intereses/BAIT |
| R2 | BAIT/Ventas |
| R3 | BAIT/Intereses |
| R4 | Resultado Neto/Pasivo Total |
| R5 | (Fondos Propios - Resultado Neto)/Pasivo Circulante |
| R6 | Fondos Propios/Pasivo Total |
| R7 | Pasivo Fijo/Pasivo Total |
| R8 | Activo Circulante/Activo Total |
| R9 | (Activo Circulante-Pasivo Circulante)/Activo Total |
| R10 | (Activo Circulante-Pasivo Circulante)/Pasivo Total |
| R11 | (Activo Circulante-Pasivo Circulante)/Ventas |
| R12 | Resultado Neto/(Activo Circulante-Pasivo Circulante) |
| R13 | Cash Flow Operativo/Activo Total |
| R14 | Cash Flow Operativo/Pasivo Total |
| R15 | Cash Flow Operativo/Pasivo Circulante |
| R16 | Cash Flow Operativo/Ventas |
| R17 | Existencias/Pasivo Circulante |
| R18 | BAIT/Activo Total |
| R19 | Resultado Neto/Ventas |
| R20 | Resultado Neto/Activo Total |
| R21 | Resultado Neto/Fondos Propios |
| R22 | (Activo Circulante- Existencias)/Ventas |
| R23 | Existencias/Ventas |
| R24 | Ventas/Activo Circulante |
| R25 | Ventas/Activo Fijo |
| R26 | Ventas/Activo Total |
| R27 | Ventas/(Existencias-Pasivo Circulante) |
| R28 | (Activo Circulante- Existencias)/Pasivo Circulante |
| R29 | Activo Circulante/Pasivo Circulante |
| R30 | Activo Fijo/Fondos Propios |
| R31 | Pasivo Total/Activo Total |
| R32 | Fondos Propios/Activo Total |
| R33 | Pasivo Circulante/Activo Total |
| R34 | (BAIT- Intereses)/Pasivo Circulante |
| R35 | Tesorería/ Pasivo Circulante |
| R36 | Tesorería/ Ventas |

4.2. Modelos Neuronales.

En el desarrollo de los modelos se ha empleado el entorno de desarrollo de redes neuronales artificiales EasyNN [EasyNN, versión 8.01, 1999-2001], sobre plataforma PC bajo Windows XP-Pro, con el algoritmo Back-Propagation.

Se experimentó con diferentes configuraciones de redes neuronales (una, dos o tres capas ocultas, diferentes cantidades de nodos,...)

Los siguientes valores se fijaron constantes en el aprendizaje para todos los modelos.

Tabla 9. Valores Constantes en el aprendizaje de todos los modelos.

| DESCRIPCIÓN | VALOR |
|------------------------------|--------------|
| Nº Ejemplos de Entrenamiento | 90 |
| Nº Ejemplos de Verificación | 36 |
| <i>Learning Rate</i> | 0,6 |
| Coeficiente de Momento | 0,8 |
| Error Medio | 0,05 |

En cada modelo se determinan los errores que se producen en la fase de verificación para obtener un indicador de la calidad de la red para asignar la calificación adecuada al modelo simulado de S&P.

Hsu(2002) también indica que la precisión de los modelos es mejor cuanto menor es el número de categorías que deben ser calificadas. Por esta razón se pretende analizar los resultados que proporcionan los modelos al agrupar en tres categorías: Grado de Inversión (AAA, AA, A, BBB), Grado Especulativo (BB, B, CCC) y Grado de Impago (CC, D) siguiendo el estudio de Caravaglia(1991).

4.2.1. Modelo Número 1.

En la Tabla 9 se muestra el resumen de los parámetros que se han utilizado en la construcción del primer modelo.

Tabla 9. Parámetros del modelo Número 1

| PARÁMETRO | CANTIDAD |
|-----------------------|----------|
| Nodos de Entrada | 6 |
| Capas Ocultas | 1 |
| Nodos en Capa Oculta | 10 |
| Nodos Salida | 1 |
| Ciclos de aprendizaje | 24214 |

Una vez entrenada la red se le presentan los ejemplos de verificación y se anotan los resultados de calificación en la Tabla 10.

Tabla 10. Resultados de la verificación del modelo Número 1.

| RATING ACTUAL | ACIERTOS DEL MODELO | PORCENTAJE DE ACIERTOS |
|---------------|---------------------|------------------------|
| AAA | 1 | 25% |
| AA | 1 | 25% |
| A | 2 | 50% |
| BBB | 0 | 0% |
| BB | 1 | 25% |
| B | 0 | 0% |
| CCC | 0 | 0% |
| CC | 0 | 0% |
| D | 1 | 25% |
| Total | 6 | 17% |

Los resultados para la agrupación en tres categorías se muestran en la tabla 11.

Tabla 11. Calificaciones para tres categorías acertadas por el modelo Número 1

| CLASE DE RATING | % ACIERTOS |
|-----------------------------------|---------------|
| Grado de Inversión | 81,25% |
| Grado Especulativo | 33,33% |
| Grado De Impago | 37,50% |
| Precisión Media del Modelo | 55,56% |

4.2.2. Modelo Número 2.

En la Tabla 12 figura el resumen de los parámetros que se han utilizado en la confección del primer modelo.

Tabla 12. Parámetros del modelo Número 2.

| PARÁMETRO | CANTIDAD |
|-----------------------|----------|
| Nodos de Entrada | 6 |
| Capas Ocultas | 2 |
| Nodos en Capa Oculta | 10+3 |
| Nodos Salida | 1 |
| Ciclos de aprendizaje | 22.867 |

Una vez entrenada la red se le presentan los ejemplos de verificación y se anotan los resultados de calificación en la Tabla 13.

Tabla 13. Resultados de la verificación del modelo Número 2.

| RATING ACTUAL | ACIERTOS DEL MODELO | PORCENTAJE DE ACIERTOS |
|----------------------|----------------------------|-------------------------------|
| AAA | 0 | 0% |
| AA | 0 | 0% |
| A | 1 | 25% |
| BBB | 0 | 0% |
| BB | 1 | 25% |
| B | 1 | 25% |
| CCC | 4 | 100% |
| CC | 1 | 25% |
| D | 2 | 50% |
| Total | 10 | 28% |

Los resultados para la agrupación en tres categorías se anotan en la tabla14.

Tabla 14. Calificaciones para tres categorías acertadas por el modelo Número 2.

| CLASE DE RATING | PORCENTAJE CORRECTO |
|-----------------------------------|----------------------------|
| Grado de Inversión | 31,25% |
| Grado Especulativo | 66,67% |
| Grado De Impago | 50,00% |
| Precisión Media del Modelo | 47,22% |

4.2.3. Modelo Número 3.

En la Tabla 15 aparece el resumen de los parámetros que se han utilizado en la construcción del primer modelo.

Tabla 15. Parámetros del modelo Número 3.

| PARÁMETRO | CANTIDAD |
|-----------------------|-----------------|
| Nodos de Entrada | 15 |
| Capas Ocultas | 1 |
| Nodos en Capa Oculta | 11 |
| Nodos Salida | 1 |
| Ciclos de aprendizaje | 18.258 |

Una vez entrenada la red se le presentan los ejemplos de verificación y se anotan los resultados de calificación en la Tabla 16.

Tabla 16. Resultados de la verificación del modelo Número 3.

| RATING ACTUAL | ACIERTOS DEL MODELO | PORCENTAJE DE ACIERTOS |
|----------------------|----------------------------|-------------------------------|
| AAA | 0 | 0% |
| AA | 1 | 25% |
| A | 0 | 0% |
| BBB | 0 | 0% |
| BB | 0 | 0% |
| B | 0 | 0% |
| CCC | 1 | 25% |
| CC | 2 | 50% |
| D | 4 | 100% |
| TOTAL | 8 | 22% |

Los resultados para la agrupación en tres categorías se recogen en la tabla 17.

Tabla 17. Calificaciones para tres categorías acertadas por el modelo Número 3.

| CLASE DE RATING | PORCENTAJE CORRECTO |
|-----------------------------------|---------------------|
| Grado de Inversión | 17,65% |
| Grado Especulativo | 16,67% |
| Grado De Impago | 100,00% |
| Precisión Media del Modelo | 35,14% |

4.2.4. Modelo Número 4.

En la Tabla 18 se incluye el resumen de los parámetros que se han utilizado en la construcción del primer modelo.

Tabla 18. Parámetros del modelo Número 4

| PARÁMETRO | CANTIDAD |
|-----------------------|----------|
| Nodos de Entrada | 15 |
| Capas Ocultas | 2 |
| Nodos en Capa Oculta | 11+4 |
| Nodos Salida | 1 |
| Ciclos de aprendizaje | 14.749 |

Una vez entrenada la red se le presentan los ejemplos de verificación y se anotan los resultados de calificación en la Tabla 19.

Tabla 19. Resultados de la verificación del modelo Número 4.

| RATING ACTUAL | ACIERTOS DEL MODELO | PORCENTAJE ACIERTOS |
|---------------|---------------------|---------------------|
| AAA | 0 | 0% |
| AA | 0 | 0% |
| A | 0 | 0% |
| BBB | 1 | 25% |
| BB | 1 | 25% |
| B | 1 | 25% |
| CCC | 1 | 25% |
| CC | 2 | 50% |
| D | 4 | 100% |
| Total | 10 | 28% |

Los resultados para la agrupación en tres categorías se pueden ver en la tabla 20.

Tabla 20. Calificaciones para tres categorías acertadas por el modelo Número 4.

| CLASE DE RATING | PORCENTAJE CORRECTO |
|-----------------------------------|---------------------|
| Grado de Inversión | 12,50% |
| Grado Especulativo | 57,14% |
| Grado De Impago | 100,00% |
| Precisión Media del Modelo | 50,00% |

4.2.5. Modelo Número 5.

En la Tabla 21 se muestra el resumen de los parámetros que se han utilizado en la construcción del primer modelo.

Tabla 21. Parámetros del modelo Número 5.

| PARÁMETRO | CANTIDAD |
|-----------------------|----------|
| Nodos de Entrada | 36 |
| Capas Ocultas | 1 |
| Nodos en Capa Oculta | 9 |
| Nodos Salida | 1 |
| Ciclos de aprendizaje | 5.736 |

Una vez entrenada la red se le presentan los ejemplos de verificación y se anotan los resultados de calificación en la Tabla 22.

Tabla 22. Resultados de la verificación del modelo Número 5.

| RATING ACTUAL | ACIERTOS DEL MODELO | PORCENTAJE ACIERTOS |
|----------------------|----------------------------|----------------------------|
| AAA | 0 | 0% |
| AA | 0 | 0% |
| A | 1 | 25% |
| BBB | 3 | 75% |
| BB | 1 | 25% |
| B | 0 | 0% |
| CCC | 2 | 50% |
| CC | 1 | 20% |
| D | 3 | 75% |
| Total | 11 | 30% |

Los resultados para la agrupación en tres categorías se aprecian en la tabla 23.

Tabla 23. Calificaciones para tres categorías acertadas por el modelo Número 5.

| CLASE DE RATING | PORCENTAJE ACIERTOS |
|-----------------------------------|----------------------------|
| Grado de Inversión | 87,50% |
| Grado Especulativo | 25,00% |
| Grado De Impago | 88,89% |
| Precisión Media del Modelo | 67,57% |

4.2.6. Modelo Número 6.

En la Tabla 24 se configura el resumen de los parámetros que se han utilizado en la construcción del primer modelo.

Tabla 24. Parámetros del modelo Número 6.

| PARÁMETRO | CANTIDAD |
|-----------------------|-----------------|
| Nodos de Entrada | 36 |
| Capas Ocultas | 2 |
| Nodos en Capa Oculta | 21+ 9 |
| Nodos Salida | 1 |
| Ciclos de aprendizaje | 4.842 |

Una vez entrenada la red se le presentan los ejemplos de verificación y se anotan los resultados de calificación en la Tabla 25.

Tabla 25. Resultados de la verificación del modelo Número 6.

| RATING ACTUAL | ACIERTOS DEL MODELO | PORCENTAJE DE ACIERTOS |
|----------------------|----------------------------|-------------------------------|
| AAA | 1 | 25% |
| AA | 1 | 25% |
| A | 0 | 0% |
| BBB | 3 | 75% |
| BB | 0 | 0% |
| B | 1 | 25% |
| CCC | 1 | 25% |
| CC | 1 | 20% |
| D | 1 | 25% |
| Total | 9 | 24% |

Los resultados para la agrupación en tres categorías se exponen en la tabla 26.

Tabla 26. Calificaciones para tres categorías acertadas por el modelo Número 6.

| CLASE DE RATING | PORCENTAJE CORRECTO |
|-----------------------------------|---------------------|
| Grado de Inversión | 50,00% |
| Grado Especulativo | 33,33% |
| Grado De Impago | 66,67% |
| Precisión Media del Modelo | 48,65% |

4.2.7. Modelo Número 7.

En la Tabla 27 se muestra el resumen de los parámetros que se han utilizado en la construcción del primer modelo.

Tabla 27. Parámetros del modelo Número 7.

| PARÁMETRO | CANTIDAD |
|-----------------------|-----------|
| Nodos de Entrada | 36 |
| Capas Ocultas | 3 |
| Nodos en Capa Oculta | 21+ 9 + 4 |
| Nodos Salida | 1 |
| Ciclos de aprendizaje | 9.423 |

Una vez entrenada la red se le presentan los ejemplos de verificación y se anotan los resultados de calificación en la Tabla 28.

Tabla 28. Resultados de la verificación del modelo Número 7.

| RATING ACTUAL | ACIERTOS DEL MODELO | PORCENTAJE DE ACIERTOS |
|---------------|---------------------|------------------------|
| AAA | 0 | 0% |
| AA | 2 | 50% |
| A | 1 | 25% |
| BBB | 0 | 0% |
| BB | 0 | 0% |
| B | 0 | 0% |
| CCC | 2 | 50% |
| CC | 1 | 20% |
| D | 3 | 75% |
| Total | 9 | 24% |

Los resultados para la agrupación en tres categorías se recogen en la tabla29.

Tabla 29. Calificaciones para tres categorías acertadas por el modelo Número 7.

| CLASE DE RATING | PORCENTAJE CORRECTO |
|-----------------------------------|---------------------|
| Grado de Inversión | 25,00% |
| Grado Especulativo | 33,33% |
| Grado De Impago | 44,44% |
| Precisión Media del Modelo | 32,43% |

5. DISCUSIÓN DE RESULTADOS.

Los resultados obtenidos con los siete modelos ensayados ofrecen varias conclusiones.

1. La primera indica que todos los modelos proporcionan resultados un tanto pobres en la asignación de 9 categorías de *rating* y mejoran los valores de aproximación media con un menor número de categorías de salida. Estos datos, coherentes con los obtenidos en trabajos anteriores (Hsu, 2002), indican la existencia de puntos críticos en la modelización perseguida. Garavaglia(1991) ofrece las siguientes posibles explicaciones:

- Insuficiente número de nodos en las capas ocultas.
- Las categorías individuales no están suficientemente diferenciadas

- Los datos de partida no aportan la información necesaria para diferenciar las categorías.

La primera razón la descartamos debido a las pruebas realizadas, generando modelos con mayor número de capas ocultas y entrenándolos con los mismos ejemplos. Los resultados indican que las calificaciones son mejores con menor número de capas ocultas excepto en el caso del modelo que utiliza las 15 variables de la cuenta de resultados.

La segunda y tercera razón están relacionadas con el carácter cualitativo de las calificaciones y la carga subjetiva que aportan los expertos de la agencia a la hora de valorar la empresa con respecto a su situación en el entorno. Las agencias de calificación insisten en la importancia de los juicios de valor lanzados por los expertos a partir de información no financiera. Diversos autores coinciden en afirmar que la memoria anual de resultados y las notas del balance de estado contienen información oculta utilizada por los expertos a la hora de emitir el *rating* de una empresa. Hsu(2002)

Esto explicaría que dos empresas, aparentemente con los mismos resultados, obtuvieran diferentes calificaciones por factores de posición competitiva respecto a su sector o por cuestiones relativas al equipo de Gestión de la empresa. Por tanto, el límite que separa las categorías no se puede establecer en valores absolutos y resulta complicado formular un modelo genérico sin la aportación de expertos humanos.

Por otro lado, en los trabajos realizados por Peel et al.(1986) y por Keasey et al.(1987) ya se intuye la carencia de los modelos basados exclusivamente en ratios financieras para predecir el fracaso empresarial y, por este motivo, trataron de incorporar otra información no cuantitativa, contenida en la memoria anual de resultados, como son los cambios en el Consejo de Dirección y movimientos de acciones durante los últimos años, cambios de Auditores de Cuentas, retrasos en la formulación de las cuentas anuales, etc. La principal barrera para incorporar esta información en una herramienta de clasificación, con poca o nula intervención humana, radica en la falta de una estructura genérica en la forma de presentar los datos en la memoria y las notas adjuntas al balance de situación que se traducen concretamente en multitud de denominaciones posibles para un mismo concepto y derivan hacia la necesidad de la intervención humana para filtrar la información.

Hsu(2002) considera que los modelos de redes neuronales no consiguen mejores resultados debido a la información suplementaria que manejan los expertos de las agencias de calificación y que, si esa información se introduce en una red neuronal, los resultados de las calificaciones proporcionadas por el mismo alcanzarían una precisión similar a la ofrecida por los expertos. En este sentido ensaya técnicas de “*text mining*” para buscar información adicional dentro de las notas del balance de estado y concluye que dicha información supone una mejora de los resultados de calificación.

2. Los modelos que utilizan 36 ratios (Números 5,6 y 7), muestran una mejor calificación de las empresas repartiéndolas a lo largo de toda la escala con mayor uniformidad que los otros modelos. Siguiendo con la explicación del punto anterior, y suponiendo eliminado el problema de la correlación entre variables, parece claro que mayor número de ratios proporciona mayor información al modelo y por tanto, mayor capacidad para discriminar las categorías.

3. El modelo Número 2, que utiliza 2 capas ocultas y 6 ratios, proporciona una buena clasificación de las categorías más bajas de la escala y resultados satisfactorio en la clasificación en tres categorías. Ésto concuerda con los estudios previos (Hsu, 2002) y pone de manifiesto que cuando se trata de pocas categorías los límites aparecen mejor definidos, permitiendo que una adecuada selección de variables significativas contenga la información necesaria para clasificarlas.

4. Los modelos Número 3 y 4, que utilizan 15 variables directamente extractadas de la cuenta de resultados, no proporcionan buenos resultados de valores medios. Sin embargo, las calificaciones que realizan en las capas inferiores de la escala, es decir, los *ratings* D, CC y CCC asociados a las empresas con mayor riesgo crediticio, aportan calificaciones acertadas en la mayoría de los casos de verificación.

6. CONCLUSIONES.

El objetivo de este trabajo era buscar una herramienta basada en redes neuronales que permitiese elaborar una calificación del riesgo crediticio de las empresas semejante a la realizada por Standard&Poor's.

Se ha experimentado con diversos modelos que proporcionan resultados análogos a los alcanzados en trabajos anteriores (Hsu, 2002). Estos resultados muestran que cuanto mayor es el número de ratios empleadas mejores resultados se obtienen en la clasificación de múltiples categorías y menos ciclos de entrenamiento son necesarios.

Los modelos de experimentación a partir de datos de la cuenta de resultados, sin realizar ningún tipo de cálculo matemático sobre ellos, tienen un aprendizaje y una convergencia más lenta. En cambio, la capacidad de calificar correctamente aquellas empresas con mayor riesgo (D, CC, CCC) abre una línea de investigación para futuros trabajos que deberán estudiar la influencia de emplear un mayor número de datos para la capa de entrada y las variaciones en la precisión provenientes de utilizar diferentes capas ocultas y un mayor número de nodos.

En el estado actual, el modelo Número 5 es el que proporciona los mejores resultados de calificación distribuida a lo largo de toda la escala y con un elevado porcentaje de aciertos en la calificación agrupada en las tres categorías, lo que indica que los errores de gran calado, como por ejemplo, calificar una empresa del tipo AAA como de tipo D o viceversa, tienen una probabilidad de ocurrencia muy baja.

Sin embargo, tal como veíamos en el apartado anterior, los valores de precisión alcanzados en la etapa de verificación son demasiado bajos como para dar credibilidad a las calificaciones alcanzadas. La explicación fundamental de estos resultados no apunta a la incapacidad de los modelos neuronales para calificar empresas, sino más bien, indica la insuficiencia de la información contenida en los ratios públicos manejados en la simulación frente a la información utilizada por los expertos de las agencias para emitir las calificaciones de rating. Será necesario incorporar parámetros cualitativos, semejantes a los enumerados por Peel et al.(1986) y Keasey et al.(1987), y segmentar por sector de actividad y tamaño de la empresa los modelos de calificación en trabajos posteriores para evaluar su influencia y su capacidad de aumentar el grado de fiabilidad de los resultados. Este punto obliga a desarrollar previamente una herramienta de extracción de datos no financieros a partir de la memoria anual, utilizando técnicas de text mining (Hsu, 2002) o búsquedas estructuradas, que proporcione información relevante de forma organizada para alimentar los modelos neuronales con información análoga a la empleada por las agencias de rating.

Es de esperar que la puesta en marcha de estas extensiones futuras del experimento se traduzca en una mejora sustancial de las calificaciones proporcionadas por la herramienta y permita su aplicación práctica.

7. BIBLIOGRAFÍA.

- 1 . "Corporate Ratings Criteria". En Internet el día 30 mayo de 2004 www.standardandpoors.com
- 2 . "Credit Rating Criteria". En Internet: www.standardandpoors.com/rating
BANEGAS OCHOVO, R.; SANCHEZ-MAYORAL, F.; NEVADO, D.; 1998; "Análisis por ratios de los estados contables financieros"; Ed. Civitas; Madrid
- 3 . DUTTA, S.; SHEKHAR, S.; 1988; "Bond rating: a nonconservative application of neural networks"; Neural Networks; IEEE International Conference on, 24-27 July; Vol.2; Pags. 443-450
- 4 . GARAVAGLIA, S.; 1991; "An application of a counter-propagation neural network: simulating Standard and Poor's Corporate Bond Rating system"; Artificial Intelligence on Wall Street; Proceedings First International Conference on, 9-11 Oct.; Pgs. 278-287
- 5 . HSU, C.; 2002; "Credit Rating Prediction with Neural Networks, Support Vector Machines, and Text Mining"; En Internet <http://monet.ecom.arizona.edu/msr/cgi-bin/all-projects.pl?from=3> el día 6 Julio de 2004
- 6 . KEASEY, K.; WATSON, R.; 1987; "Non-Financial symptoms and the prediction small company failure. A test of Argenti's hypotheses"; Journal of Business Finance and Accounting; Autumn, Vol. 14; N° 3; Pags 335-354
- 7 . KIM, B.-O.; LEE, S.M.; CHO, J.Y.; HUNTER, M.; 1991; "A computational model of bond rating"; Artificial Intelligence on Wall Street; Proceedings First International Conference on, 9-11 Oct.; Pgs. 272-277
- 8 . LEK, S.; GUEGAN, J.F.; 2000; "Artificial neuronal networks. Application to ecology and evolution"; Ed. Berlin Springer. Berlin, Springer
- 9 . LEV, B.; 1978; "Análisis de estados financieros: un nuevo enfoque"; Ed. ESIC; Madrid
- 10 . LOPEZ PASCUAL, J.; 1996; "El rating y las agencias de calificación"; Ed. Dykinson S.L.; Madrid
- 11 . PEEL, M.; PEEL, D.; POPE, P.; 1986; "Predicting corporate failure. Some results for de UK Corporate Sector"; OMEGA; Vol. 14; N° 1; Pags 5-12
- 12 . SHAW, M.J.; GENTRY, J.A.; 1990; "Inductive Learning for risk classification"; Expert IEEE; Vol. 5; Issue: 1; Pgs. 47-53
- 13 . SIMON, H.A.; 2003; "La racionalidad limitada en Ciencias Sociales: Hoy y mañana"; En: González, W.J. (Ed.), Racionalidad, historicidad y predicción en Herbert A. Simon, Netbiblo, S.L.; A Coruña; pp. 97-110.
- 14 . SURKAN, A.J.; CLAY SINGLETON, J.; 1990; "Neural networks for bond rating improved by multiple hidden layers"; Neural Networks; International Joint Conference on, 1 June, Vol .2; Pgs. 157-162
- 15 . SURKAN, A.J.; CLAY SINGLETON, J.; 1992; "Neural networks as bond rating tools"; System Sciences; Proceedings of the Twenty-fifth Hawaii International Conference on Volume: iv; 7-10 Jan.; Vol. 4; Pgs. 499-503
- 16 . UTANS, J.; MOODY, J.; 1991; "Selecting neural network architectures via the prediction risk: application to corporate bond rating prediction"; Artificial Intelligence on Wall Street; Proceedings First International Conference on, 9-11 Oct.; Pgs. 35-41
- 17 . VERONA MARTEL, M.C.; 2002; "El rating como evaluación de la calidad crediticia de las empresas"; Servicio de Publicaciones de la Universidad de Las Palmas de Gran Canaria; Las Palmas de Gran Canaria.
- 18 . WALSH, C.; 2000; "Ratios fundamentales de gestión empresarial"; Ed. Prentice Hall; Madrid
- 19 . www.sec.gov
- 20 . www.cajamadrid.es