

**UNIVERSIDAD NACIONAL DE INGENIERIA
FACULTAD DE INGENIERÍA INDUSTRIAL Y DE
SISTEMAS
SECCIÓN DE POSTGRADO**



**IDENTIFICACION DE LA SOLVENCIA O INSOLVENCIA
EMPRESARIAL MEDIANTE REDES NEURONALES**

TESIS

**PARA OPTAR EL GRADO ACADEMICO
DE MAESTRO EN CIENCIAS
CON MENCION EN
INGENIERIA DE SISTEMAS**

ING. ANCO CHAMBILLA GUIDO

ING. MONTESINOS CHÁVEZ FERMÍN ROLANDO

LIMA - PERU

2010

Digitalizado por:

**Consortio Digital del
Conocimiento MebLatam,
Hemisferio y Dalse**

DEDICATORIA

A Marlo, la razón de mi vida

DEDICATORIA

A mi familia por el apoyo
incondicional en todo momento

AGRADECIMIENTOS,

A Dios, por ser siempre nuestra fortaleza

A nuestros padres, a quienes les debemos todo lo que somos y todo lo que tenemos.

A nuestros asesores Dr. José Portillo Campbell, Dr. Alberto Un Jan Liao Hing y Mg. Abilio Tinoco León por su infinita paciencia, consejos y enseñanzas.

A todos nuestros profesores de la Escuela de Postgrado por enseñarnos el poder del conocimiento.

A nuestro país Perú

INDICE

CONTENIDO	PAG.
RESUMEN	
DESCRIPTORES TEMATICOS	
INTRODUCCION	01
CAPÍTULO I: PLANTAMIENTO DE LA INVESTIGACION	03
1.1. DIAGNÓSTICO Y ENUNCIADO DEL PROBLEMA	03
1.1.1. Antecedentes del problema	03
1.2. DEFINICIÓN DEL PROBLEMA DE INVESTIGACIÓN	07
1.3. DELIMITACIÓN DE LOS OBJETIVOS	08
1.3.1. Objetivo General	08
1.3.2. Objetivos Específicos	09
1.4. HIPOTESIS DE LA INVESTIGACION	09
1.4.1. Hipótesis General	09
1.4.2. Hipótesis Específicas	09
1.5. JUSTIFICACION Y DELIMITACION DE LA INVESTIGACION	09
1.5.1. Importancia del Tema	09
1.5.2. Justificación	10
1.5.3. Delimitación	11
CAPITULO II: MARCO TEORICO	14
2.1. ANTECEDENTES DE LA INVESTIGACION	14
2.2. MARCO TEORICO	17
2.2.1. Análisis Financiero	23

2.2.2. Modelos Estadísticos	34
2.2.2.1. Análisis Discriminante Múltiple	36
2.2.2.2. Contraste de significación y evaluación de la bondad del ajuste	43
2.2.3. Inteligencia Artificial	44
2.2.4. Redes Neuronales Artificiales (RNA)	47
2.2.4.1. El Modelo Biológico	47
2.2.4.2. Neurona Artificial	51
2.2.4.3. Aprendizaje de las Redes Neuronales Artificiales	53
2.2.4.4. Topología de las Redes Neuronales	56
2.2.4.5. PERCEPTRON Multicapas (MLP)	57
2.2.4.5.1. Funcionamiento de las redes PERCEPTRON Multicapas	59
2.2.4.5.2. Aprendizaje de las redes PERCEPTRON Multicapas	60
2.2.4.5.3. Campos de Aplicación	61
2.2.4.6. Red de Funciones de Base Radial (FBR)	61
2.2.4.6.1. Función de Base Radial (FBR)	61
2.2.4.6.2. Arquitectura de la FBR	63
2.2.4.6.3. Algoritmo de Aprendizaje en la (FBR)	66
2.2.4.6.4. Aprendizaje en dos fase	66
2.2.4.6.5. Entrenamiento de las neuronas ocultas Gaussianas	66
2.2.4.6.6. Entrenamiento de las neuronas de salida	69
CAPITULO III: METODOLOGIA DE LA INVESTIGACION	70
3.1. TIPO DE INVESTIGACION	70
3.2. DISEÑO DE LA INVESTIGACION	70
3.3. POBLACION Y MUESTRA	71
3.3.1. Población o Universo	71
3.4. VARIABLES E INDICADORES	73

CAPITULO V: CONCLUSION Y RECOMENDACIONES	149
5.1. CONCLUSIONES	149
5.2. RECOMENDACIONES	151
BIBLIOGRAFIA	152
CITAS BIBLIOGRAFICAS	152
ANEXOS	161

RESUMEN

Actualmente la crisis mundial y la situación de recesión en los países desarrollados, repercute en nuestro país que hace que muchas empresas pasarán una etapa crítica, por lo cual, es necesario construir sistemas que incorporen conocimientos y, de esta manera, sirvan de ayuda a los procesos de toma de decisiones en el ámbito de la gestión empresarial relacionado a la identificación de la solvencia o insolvencia que atraviesa algunas empresas. Esto ha llevado a realizar la siguiente investigación utilizando sofisticados métodos de identificación de la solvencia, y entre estos se encuentra aquellos que están basados en técnicas de inteligencia artificial y ocupan un papel destacado como son las redes neuronales artificiales, utilizando como atributos los ratios financieros, que mediante el aprendizaje supervisado simplifican y aceleran el procesamiento de la información, se buscarán patrones y tendencias que puedan revelar y predecir el comportamiento de la situación financiera de las empresas.

El objetivo de esta investigación consiste en desarrollar un modelo basado en redes neuronales artificiales capaz de identificar la solvencia o insolvencia empresarial, teniendo en consideración los ratios financieros, así como también realizar un análisis comparativo con un modelo Análisis Discriminante Múltiple utilizado como referencia para determinar que modelo proporciona los mejores resultados.

Aunque los resultados no son concluyentes, en general las redes neuronales han mostrado una capacidad de identificación de la solvencia o insolvencia

empresarial igual o superior que las técnicas estadísticas, con la ventaja de poderse utilizar independientemente del cumplimiento de los supuestos teóricos relativos a estas técnicas. Se presentan una serie de simulaciones y aplicaciones sobre datos reales que apoyan esta idea. En concreto contrastamos el análisis discriminante contra dos tipos de redes neuronales artificiales; PERCEPTRO Multicapa y la de Función de Base Radial en tareas de identificación, manipulando los patrones de correlación existentes entre los predictores (o variables de entrada) por un lado y la variable de salida por el otro. Los resultados muestran que las redes neuronales artificiales identifican con mayor exactitud que las técnicas estadísticas. La red neuronal PERCENTRON Multicapa con aprendizaje por retropropagación de error (Back-propagation), con la siguiente configuración: con una capa de entrada compuesta por 6 neuronas en la capa de entrada, 15 neuronas en la capa y una capa de salida de una sola neurona, es la que mejor desempeño tuvo en la identificación de la solvencia e insolvencia empresarial.

DESCRIPTORES TEMATICOS

- **Redes Neuronales Artificiales**
- **Análisis Discriminante Múltiple**
- **Análisis Financiero**
- **Solvencia**
- **Insolvencia**

INTRODUCCION

Los procedimientos sistemáticos aplicados a la toma de decisiones gerenciales, se han basado históricamente en medios cuya evolución ha progresado a medida que aumentaba la complejidad de las relaciones empresariales. Así, con anterioridad a la aplicación del método científico, en la resolución de problemas relativos a la actividad económica y empresarial, las decisiones se adoptaban de forma individual por la propia persona que toma la decisión, sobre la base del binomio, experiencia-intuición.

Desde mediados de siglo pasado, la contribución de la informática fue fundamental para procesar la información que la empresa generaba en su entorno, proporcionando a la gerencia los medios suficientes y una amplia capacidad de decisión en el desarrollo de su actividad. No obstante, en este proceso no se produjeron aún adelantos sustanciales, sencillamente, los avances informáticos simulaban las funciones ejecutadas por el procedimiento manual, consiguiendo que los requerimientos informativos legales a cubrir por las entidades se asegurasen de forma rápida y eficaz, pero ignorando un ámbito mucho más amplio que tuviese por objetivo cubrir las nuevas necesidades de toma de decisiones para la gestión de empresas en una economía, globalizada y enormemente competitiva.

Por lo que los investigadores en sistemas de tratamiento de datos financieros han reconocido las dificultades que plantean los sistemas de procesamiento de la información para responder a las nuevas exigencias en

la mayoría de las empresas, entre otras, por las siguientes razones: los sistemas tradicionales no cubren las necesidades informativas de los usuarios, en casos que se aporte un amplio caudal de información, la imposibilidad de los humanos de procesar o comprender lo suministrado en los datos contables, y en todo caso, por la limitación que supone centrarse tan sólo en procesar datos numérico.

En la actualidad, los sistemas de ayuda a la decisión, han reemplazado el término información por el de conocimiento, lo cual permite incluir en el proceso de toma de decisiones aspectos cualitativos en el tratamiento de datos, así como el saber acumulado de especialistas en el área de trabajo objeto del problema a resolver, elementos, que hasta ahora no habían sido considerados en los sistemas aplicados.

Los trabajos más recientes de la Inteligencia Artificial han resaltado la importancia de los sistemas soporte de ayuda a la toma de decisiones y de la información cualitativa, sugiriendo modelos desarrollados para asistir al ente decisor en la resolución de problemas. Por un lado, los sistemas expertos tratan de representar el conocimiento de forma simbólica, partiendo de la premisa de que los expertos humanos utilizan gran número de reglas heurísticas específicas en un determinado campo, las cuales son incorporadas al sistema. Por otro lado, las redes neuronales artificiales tratan de representar el conocimiento de un modo conexionista y adaptativo, replicando la estructura neuronal del cerebro humano. Lo fundamental en este paradigma es el aprendizaje mediante patrones o ejemplos.

Existen opiniones de que introduciendo los sistemas de Inteligencia Artificial mencionados en las bases de datos de la contabilidad de las empresas, es posible ayudar a la investigación de los diferentes subsistemas de la empresa con grandes volúmenes de información, obteniendo una más amplia comprensión de la compleja realidad empresarial.

CAPÍTULO I

PLANTEAMIENTO DE LA INVESTIGACION

1.1. DIAGNÓSTICO Y ENUNCIADO DEL PROBLEMA

1.1.1. Antecedentes del problema

La década de los noventa constituye para el Perú, una etapa de profundos cambios estructurales en la economía. A partir de 1990 se pone fin al modelo de economía controlada, con excesiva presencia del Estado en la actividad productiva, aislada del resto del mundo prevaleciente, fuerte proteccionismo del estado a sus empresas hasta fines de la década de los ochenta, y entra en vigencia una economía de libre mercado, más competitiva e integrada al sistema económico mundial.

En este proceso de liberalización y globalización económica, muchas empresas experimentaron problemas de adaptación a las nuevas condiciones del mercado y se volvieron más sensibles a las crisis financieras internacionales. Así mismo la dación de la “Ley de Reestructuración Empresarial” en diciembre de 1991, Decreto Ley N° 26116, marcó un cambio radical en el modelo peruano de reestructuración empresarial: se pasó de un modelo fundamentalmente liquidatorio y judicializado, a un modelo privado que promueve la reestructuración de negocios viables. De la Ley Procesal de Quiebras de 1932¹, Ley 7566, que, como mejor solución a la crisis,

¹ Los sistemas de reestructuración empresarial también son conocidos como sistemas concursales o regímenes de insolvencia.

propició la liquidación bajo el marco de un proceso judicializado; se pasó a un modelo que en su lugar propició la reestructuración de los negocios viables, según lo que los acreedores considerasen más conveniente a sus intereses y, a su vez, limitó la intervención del Poder Judicial, trasladando el rol de supervisor del proceso a una autoridad administrativa específicamente creada para ello: el INDECOPI². Esto se evidencia a partir de 1993, cuando un número creciente de compañías comienzan a declararse en insolvencia, convirtiéndose en un problema común a nivel de pequeñas y grandes empresas. Las cifras de solicitudes para acogerse al sistema eran sostenidamente crecientes. En 1993, el número de empresas era de 90, en el año 1995 se incrementó a 133, en 1998 la cifra creció en forma exponencial llegando a 766, alcanzando su máxima expresión en los años 2000 y 2001 en el que 1.698 y 1.635 empresas respectivamente, solicitaron ser admitidas en el Sistema de Reestructuración Patrimonial por razones de insolvencia financiera. A partir de esos años, las cifras comienzan a descender hasta llegar al año 2003 con sólo 505 empresas.

Esta crisis financiera empresarial cobra matices dramáticos para la economía peruana en la medida en que el 70,3% de firmas insolventes que ingresaban ante el INDECOPI -órgano regulador de ingreso y salida del mercado- terminaban en liquidación o quiebra, y sólo el 23,9% tenían la posibilidad de reestructurarse.

En respuesta a la agudización de esta crisis, el gobierno puso en vigencia el Sistema de Reestructuración Empresarial, asignándole el rol supervisor del proceso al INDECOPI. Sin embargo, como este mecanismo no constituyó una solución al problema de las quiebras, hubo la necesidad de introducir nuevas reformas en el sistema, para lo cual se promulgó el Decreto Legislativo N° 845, "Ley de Reestructuración Patrimonial" en 1996 y la Ley N° 27146, "Ley de Fortalecimiento del Sistema de Reestructuración

² Instituto Nacional de Defensa de la Competencia y de la Propiedad Intelectual

Patrimonial” en 1999. Este marco legal además de fortalecer el Procedimiento de Insolvencia, también crea el Procedimiento Simplificado, el Concurso Preventivo y el Procedimiento Transitorio; que tampoco fueron suficientes para frenar la ola de solicitudes de insolvencia de importantes firmas en el Perú.

De acuerdo a los estudios del INDECOPI, durante el período 1993 - 2001, se han acogido al Sistema de Reestructuración Patrimonial por problemas de insolvencia financiera 5.788 empresas, que involucran a más de 450.000 trabajadores y un monto total de deudas reconocidas de 17.790 millones de Nuevos Soles. Ver cuadro N° 01.

CUADRO N° 01
PERÚ: SOLICITUDES DE DECLARATORIA DE INSOLVENCIA PRESENTADAS
A INDECOPI, 1993-2003

AÑO	SOLICITUDES PRESENTADAS	DECLARADAS INSOLVENTES	%
1993	90	44	48,9
1994	128	65	50,8
1995	133	77	57,9
1996	170	110	64,7
1997	344	116	33,7
1998	766	229	29,9
1999	824	470	57,0
2000	1.698	548	32,3
2001	1.635
2002	926
2003	505
1993-2003	7.219		

Nota: El 21 de enero de 1993 se dio inicio a la aplicación del Sistema de Reestructuración Empresarial, luego pasó a denominarse Sistema de Reestructuración Patrimonial y actualmente Sistema Concursal.

1/ No incluye solicitudes declaradas inadmisibles

Fuente: INDECOPI-Comisión de Procedimientos Concursales.

Este problema que ha venido enfrentando la economía a lo largo de esta década sobre el cual aún no se ha llegado a elaborar una teoría positiva que permita la anticipación del mismo. Por ello, desde una óptica puramente empírica, se han elaborado diversos modelos de alerta de crisis financieras.

Por lo que es necesario el interés por parte de las empresas la evaluación anticipada de la crisis financiera empresarial al permitir a la empresa disponer de un sistema de diagnóstico, que incluya aspectos de calificación de la solvencia y la rentabilidad, que ayude a corregir las deficiencias que las empresas tienen con la finalidad de mejorar su desempeño. En la medida que las empresas mantengan los niveles de solvencia y rentabilidad adecuados, podrán seguir subsistiendo como empresas viables dentro de la economía y reportando beneficios a los inversionistas y a la sociedad en su conjunto, podemos imaginarnos lo que significa que una empresa quiebre, las responsabilidades que tiene que cumplir, con sus accionistas proveedores y trabajadores.

Una metodología para este tipo de estudios es través de las razones financieras, también conocidas como análisis financiero, representa la base tradicional del análisis e interpretación de los estados financieros. Esta técnica propone el uso de estos coeficientes para la evaluación de la situación y evolución, tanto financiera como económica, de la empresa. Sin embargo, los ratios a pesar de ser un instrumento de uso frecuente, cuyo buen diseño y conocimiento permiten resolver algunos aspectos concretos para la toma de decisiones financieras, tienen una limitada capacidad para cuantificar de forma eficiente el éxito o fracaso de una empresa.

También se han planteado estudios aplicando los modelos obtenidos mediante el empleo de diferentes técnicas estadísticas como el análisis univariante que ha evolucionado de modelos no cuantitativos a modelos de regresión de una variables con otra para predecir tendencias, se ha pasado a integrar los ratios en técnicas más avanzadas como modelos estadísticos o análisis multivariable como complemento o sustituto del análisis tradicional y dentro del análisis financiero contemporáneo, parte del hecho de que determinar el éxito o fracaso de una empresa constituye un tema complejo, esto por interactuar varios factores simultáneamente y combinados entre sí. Además, el principal problema en realidad radica en determinar el peso

específico o la contribución marginal que tienen cada uno de esos factores dentro de un análisis financiero integral con fines predictivos (preventivos o correctivos).

En los últimos años se han impulsado el desarrollo de nuevos y más sofisticados métodos para realizar predicciones sobre el comportamiento de series financieras mediante el uso de redes neuronales artificiales, para ser comparadas con otras metodologías tradicionales, mostrando excelentes resultados ya que las redes neuronales son capaces de identificar relaciones no lineales, y de no requerir un modelo fenológico para describir la distribución de los datos, ya que pueden aprender a partir de muestras y permiten implementar de forma sencilla algoritmos de discriminación basados en funciones no lineales si fuera necesario.

Por tal motivo, el presente trabajo planteamos las innovaciones más recientes y destacables en uno de los paradigmas las redes neuronales artificiales, motivadas en modelar la forma de procesamiento de la información en sistemas nerviosos biológicos. Especialmente, por la forma de funcionamiento del cerebro humano, que es completamente distinta al funcionamiento de un computador digital convencional.

1.2. Definición del problema de investigación

Actualmente la crisis mundial y la situación de recesión en los países desarrollados, repercute en nuestro país que hace que muchas empresas pasarán una etapa crítica, por lo cual, es necesario construir sistemas que incorporen conocimientos y, de esta manera, sirvan de ayuda a los procesos de toma de decisiones en el ámbito de la gestión empresarial relacionado a la identificación de la solvencia o insolvencia que atraviesa algunas empresas. Esto ha llevado a realizar la siguiente investigación utilizando sofisticados métodos de identificación de la solvencia, y entre estos se encuentra aquellos que están basados en técnicas de inteligencia artificial y

ocupan un papel destacado como son la redes neuronales artificiales, utilizando como atributos los ratios financieros, que mediante el aprendizaje supervisado simplifican y aceleran el procesamiento de la información, se buscarán patrones y tendencias que puedan revelar y predecir el comportamiento de la situación financiera de las empresas.

Por esta razón, el desarrollo de la presente investigación pretende responder a la siguiente interrogante:

¿Un modelo basado en redes neuronales (redes de neuronas PERCEPTRON Multicapa o redes de Función Base Radial) es capaz de identificar la solvencia o insolvencia empresarial, así como también mejorar los resultados obtenidos con un modelo de análisis discriminante multivariable, teniendo en consideración los ratios financieros?

A partir de la cual se plantean las siguientes preguntas específicas:

- ¿El modelo propuesto basado en redes neuronales artificiales identifica mejor la solvencia o insolvencia empresarial que el modelo Análisis Discriminante Multivariante usado como referencia?
- ¿Los ratios financieros seleccionados como variables de entrada al modelo propuesto basado en redes neuronales artificiales identifica con mayor exactitud la solvencia o insolvencia empresarial?

1.3. DELIMITACION DE LOS OBJETIVOS

1.3.1. Objetivo general

El objetivo general de esta tesis se puede expresar como:

Desarrollar un modelo basado en redes neuronales artificiales capaz de identificar la solvencia o insolvencia empresarial, teniendo en consideración los ratios financieros, así como también realizar un análisis comparativo con un modelo Análisis Discriminante Múltiple utilizado como referencia para determinar que modelo proporciona los mejores resultados.

1.3.2. Objetivos específicos

- Determinar si el modelo propuesto basado en redes neuronales artificiales identifica mejor la solvencia o insolvencia empresarial que un modelo de Análisis Discriminante Múltiple usado como referencia.
- Seleccionar los ratios financieros como variables de entrada al modelo propuesto basado en redes neuronales artificiales identifica con mayor exactitud la solvencia o insolvencia empresarial.

1.4. HIPOTESIS DE LA INVESTIGACION

1.4.1. Hipótesis general

Un modelo basado en redes neuronales artificiales es capaz de identificar la solvencia o insolvencia empresarial, así como también mejorar los resultados obtenidos por medio de un modelo análisis discriminante múltiple utilizado como referencia, teniendo en consideración los ratios financieros.

A partir de la cual se plantean las siguientes hipótesis específicas:

- El modelo propuesto basado en redes neuronales artificiales identifica con mayor exactitud la solvencia o insolvencia empresarial, que el modelo análisis discriminante múltiple usado como referencia.
- Los ratios financieros seleccionados como variables de entrada al modelo propuesto basado en redes neuronales artificial identifica con mayor exactitud la solvencia o insolvencia empresarial.

1.5. JUSTIFICACION Y DELIMITACION DE LA INVESTIGACION

1.5.1. Importancia del tema

El presente trabajo es importante porque en el caso de las finanzas aparecen aplicaciones obvias, por ejemplo:

- Clasificar, a los solicitantes de un crédito, en clientes potencialmente buenos o malos en función de determinados datos contables del negocio.
- Clasificar, a un grupo de empresas, en candidatas potenciales al fracaso o al éxito en los negocios, según ciertos ratios contables que es el problema real al que nos vamos a enfrentar.
- Para la compra/venta de acciones de una determinada empresa por parte de inversionistas.

La aplicación de las redes neuronales artificiales no requiere una previa especificación de una forma funcional lineal, ni la adopción de supuestos restrictivos acerca de las características de las distribuciones estadísticas de las variables y errores del modelo. Es decir, las redes dan la posibilidad de trabajar con variables imprecisas, cambiando los modelos a través del tiempo para que fueran capaces estos de adaptarse gradualmente a cada caso que se presentara, es un estimador no parametrizado. Debido a ello motivo la presente investigación de mostrar la capacidad de las redes neuronales de realizar predicciones, como una herramienta alterna a las técnicas estadísticas tradicionales además de explicar de manera clara y sencilla pero sin perder de vista la rigurosidad matemática que involucran este tipo de temas, el funcionamiento de una red neuronal.

1.5.2. Justificación

La intención de esta investigación es mostrar la capacidad de las Redes Neuronales Artificiales basadas en la imitación de la estructura y actividades del cerebro humano, siendo dos de sus características más relevantes la capacidad de aproximar funciones complejas y su utilidad para agrupar elementos correctamente a partir de determinadas variables por ello, pueden considerarse un instrumento alternativo para realizar predicciones sobre la solvencia e insolvencia empresarial, como una herramienta alterna a las técnicas estadísticas tradicionales como el análisis multivariante.

El estudio propuesto está diseñado para aquellas empresas o inversionistas inquietos que deseen intentar una nueva forma de valorar la situación financiera con mayor precisión y poder subsanar de este modo la desventaja que presenta el no contar con todo un equipo de expertos en finanzas para poder determinar la solvencia e insolvencia de una empresa, basado en tecnologías que han demostrado su efectividad en otras disciplinas y que ahora se aplican a empresas que se desenvuelven dentro de un mercado competitivo.

Existen pocos estudios realizados por medio de redes neuronales relacionados al presente, y los que existen son aplicados sobre todo a mercados de países desarrollados, por lo que se pretende que este estudio pueda aplicarse a distintos estados financieros de empresas de manufactura como de servicios, incrementando con ello el abanico de posibilidades que cualquier persona debe poseer para poder tomar las mejores decisiones. Es por esta razón que esta investigación se considera novedosa.

Por todo lo anterior, existe la necesidad de desarrollar un marco conceptual que permita fundamentar la propuesta metodológica de la presente tesis, y elaborar una investigación empírica con el fin de comprobar las hipótesis planteadas.

1.5.3. Delimitaciones

La investigación está enmarcada al estudio de empresas del sector industrial, extracción, comercio y de servicios. En nuestro país desde 1992 cuenta con sistema de reestructuración empresarial más moderno, que reemplazó a la inefectiva ley Procesal de Quiebras de 1932, lo que significó que durante el periodo 1993 – 2003, se acogieron 5.788 empresas al Sistema de Reestructuración Patrimonial, debido a que perdieron más de las 2/3 partes de su patrimonio social o por la incapacidad de hacer frente a sus obligaciones de corto plazo por falta de liquidez.

Este análisis permitió limitar el estudio a este periodo en vista que se requiere tener información de los estados financieros de empresa y se seleccionaran de la lista de empresas que se declararon en quiebra o insolventes de INDECOPI, el segundo grupo de empresas solventes, se obtendrán de la lista de empresas de CONASEV³, teniendo en consideración el mismo periodo, esta información servirá para el proceso de aprendizaje o entrenamiento como el de validación del modelo de redes neuronales propuesto.

Por otro lado, en el tratamiento del problema no se profundiza el análisis sobre el papel jugado por el tamaño de la empresa en la insolvencia; es decir, no se estudia en forma específica qué factores afectan más a una gran empresa y qué factores a una pequeña firma. Esto se debe a que el objetivo de la investigación se orienta al análisis de la solvencia o insolvencia en forma global, a través de una metodología no tradicional, sin tener en cuenta el tamaño de la empresa. Así mismo se ha considera el periodo 1993 -2003 donde la inflación se ha mantenido baja, las reservas internacionales han alcanzado niveles históricos y el sector financiero se ha hecho más sólido.

**CUADRO N° 02
INFLACION PROMEDIO ANUAL Y DEVALUACION EN EL PERU
(PORCENTAJES)**

AÑO	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003
Inflación (%)	23,7	11,10	11,50	8,50	7,30	3,50	3,80	2,00	0,20	2,30
Devaluación (%)	10,4	2,70	8,80	8,50	10,00	15,5	3,10	0,50	0,30	-1,10

Fuente: Banco Central de Reserva del Perú – Gerencia de Estudios Económicos, Series Estadísticas

Anuales

³ Comisión Nacional Supervisora de Empresas y Valores

En el cuadro N° 02 se observa que la tasa de inflación se ha mantenido alrededor 7,39% anual marcadamente superior a la tasa de devaluación de 5,87% promedio anual, ello ha determinado la apreciación del sol en el periodo correspondiente.

Los resultados positivos de la balanza de pagos han repercutido en una recuperación importante de las reservas internacionales netas (RIN), las que se han mantenido alrededor de 8.524.000 dólares americanos anuales en periodo considerado. Esta cifra es el equivalente a doce meses de importaciones y contribuyó a fortalecer la moneda nacional, al mismo tiempo que le otorgó solidez financiera a la economía peruana. Ver cuadro N° 03.

CUADRO N° 03
RESERVAS INTERNACIONALES NETAS DEL PERU
PERIODO 1993 – 2003

AÑO	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003
RIN (Mill. US\$)	5.718	6.641	8.540	10.169	9.183	8.404	8.180	8.613	9.598	10.194

Fuente: Banco Central de Reserva del Perú – Gerencia de Estudios Económicos, Series Estadísticas Anuales

El PBI había tenido un patrón de crecimiento oscilante durante la década de los noventa. Luego del período de hiper-recesión el proceso de recuperación de la economía produjo altas tasas de crecimiento entre 1993 y 1997, que superaron el 12,8% en 1994, y promediaron cerca de 7% anuales para dicho período. El impacto de la crisis internacional y los choques climatológicos en el país, junto con el agotamiento de las reformas de primera generación del gobierno de turno, produjeron cuatro años (1998 - 2001) de bajas tasas de crecimiento económico, cuyo promedio no alcanzó a superar el 1% anual. El 2002 y 2003, se creció, con tasas anuales superiores al 4% en esos dos años.

CAPITULO II

MARCO TEORICO

2.1. ANTECEDENTES DE LA INVESTIGACIÓN

Según Altman y Saunders (1998, p. 1.722) el análisis de la solvencia empresarial ha sufrido una gran evolución a lo largo de los últimos 20 años, debido a factores tales como el aumento en el número de quiebras, la desintermediación creciente que se observa en los mercados financieros, la disminución de los tipos de interés o el desarrollo de nuevos instrumentos financieros. Todo ello ha impulsado el desarrollo de nuevos y más sofisticados métodos de análisis de la solvencia, y entre este tipo de sistemas ocupan un papel destacado aquellos que están basados en técnicas de Inteligencia Artificial.

Una de las múltiples técnicas que emplea la Inteligencia Artificial para simular el comportamiento inteligente de los seres humanos, son las denominadas Redes Neuronales Artificiales (RNA), las mismas que seducen a profesionales de distintas disciplinas por el gran potencial que ofrecen para resolver problemas complejos. Estos fueron objeto de especial interés en los primeros tiempos de la Inteligencia Artificial (años 50 y 60). Sin embargo, los resultados no fueron alentadores, pues el escaso desarrollo que por aquellas fechas presentaba la tecnología informática provocó que muchas investigaciones acabaran en fracaso. Además, diversos trabajos como el de Minsky y Papert (1969), pusieron de manifiesto graves limitaciones en el proceso de aprendizaje de las arquitecturas de redes más usuales por aquel

entonces, esto motivó que durante la década de los 70 el interés por las redes neuronales artificiales desapareciera casi por completo.

Sin embargo, a partir de los años 80 los computadores más potentes resultando del avance de la tecnología informática y el mejor conocimiento de la estructura del cerebro humano provocaron un resurgimiento del interés por el tema, y por ello en los últimos años se constata un número creciente de aplicaciones, para diversos propósitos y en diversas áreas de estudio, entre ellas la determinación del grado de solvencia financiera y se profundizó cuando se desarrolla el algoritmo de retropropagación o back-propagation (BP), a finales de los años ochenta. Su introducción vino motivada por el deseo de mejorar los resultados que se alcanzaban con los modelos estadísticos (análisis discriminante y regresión logística, principalmente), pues estos proporcionan regiones de decisión definidas a través de funciones lineales, mientras que con la inserción de capas “ocultas” de neuronas en un modelo PERCEPTRON es posible la definición de regiones mucho más complejas y, por lo tanto, la reducción del número de empresas incorrectamente clasificadas.

Como señalan Serrano Cinca y Martín del Brío (1993, p.156), la información económica, y especialmente la que proporcionan los estados financieros de las empresas, suele constar de multitud de datos correlacionados, a veces incompletos e incluso erróneos o adulterados. Estas características son la materia prima en la que las redes neuronales proporcionan mejores resultados, ya que gozan de una elevada capacidad de filtrar los ruidos que acompañan a la información, así como de una alta tolerancia a los fallos. En el mismo sentido, Brown y O'Leary (1995, p. 10) destacan las virtudes de las redes neuronales cuando los modelos a reconocer presentan variaciones, que es precisamente lo que ocurre en el análisis de la posición financiera, pues no existe un modelo rígido y único de empresa insolvente o solvente.

Otros estudios relacionados con el tema de la solvencia, los que tratan de predecir las calificaciones otorgadas por agencias de rating (Dutta y Shekhar, 1994; Surkan y Singleton, 1990) evidencia clara superioridad de los modelos basados en redes neuronales, lo cual conduce a pensar en lo adecuado de este tipo de sistemas para modelar las decisiones de los agentes económicos. Esto entra dentro de la lógica, dado que aquellas están inspiradas en la estructura del cerebro humano.

Debido a todas estas propiedades, diversos modelos de redes han sido empleados a lo largo de los últimos años relacionados con el análisis de la solvencia, y algunos de ellos han trascendido el plano teórico para ser implementados en la práctica por parte de diversas instituciones financieras, de lo que se puede indicar los siguientes:

- En España, (Martínez de Lejarza Esparducer, 1996), utilizó un modelo PERCEPTRON Multicapa, que trata de la crisis en el sector de seguros español utilizando un PERCEPTRON muy sencillo que consta de solo dos neuronas en la capa oculta, y obtiene resultados claramente superiores a los del análisis discriminante
- Del Rey Martínez (1996), utilizó el modelo PERCEPTRON Multicapa y haciendo uso de la información contable procedente de los Registros Mercantiles de la Comunidad Valenciana, años 1992, 1993 y 1994, para el pronóstico de las situaciones de quiebra y suspensión de pagos en las empresas no financieras, a través de un PERCEPTRON con tres capas de neuronas. Este modelo también presenta la característica positiva de que el número de empresas insolventes clasificadas incorrectamente es menor que el de las solventes asignadas por error al grupo de las quebradas o insolventes.
- En las investigaciones como la de Soldevilla y Guillén (1997), llevaron a cabo un modelo por la falta de pago de préstamos concedidos a particulares por una entidad bancaria utilizando una red

PERCEPTRON entrenada a través de la retropropagación y se comparan los resultados con los del análisis logit, resultando ligeramente superior el modelo neuronal.

- López González y Flórez López, (1999), utilizan un sistema de Mapas Autoorganizados de Kohonen, técnica que ya había sido empleada en el trabajo de Serrano Cinca y Martín del Brío para el análisis de la crisis del sector bancario español durante los años setenta y ochenta, con el modelo obtenido se caracteriza adecuadamente la solvencia empresarial, obteniéndose mapas topográficos significativos y detectándose los indicadores más significativos en su formación.
- Koh y Tan (1999), establecen un PERCEPTRON Multicapa, a través de un modelo muy sencillo, con cuatro neuronas en una única capa oculta, donde abordan el problema de la predicción de la insolvencia. Los resultados indican que la red neuronal alcanza resultados tan buenos como los de un modelo probit o como los pronósticos de los auditores.

Si bien ya se han desarrollado un gran número de aplicaciones satisfactorias, algunas de las cuales están siendo utilizadas en el “mundo real”, es necesario plantear que en un futuro previsible es necesario llevar a cabo trabajos de investigación innovadores haciendo uso de otros modelos como las redes neuronales de base radial.

En la actualidad en nuestro país no se han realizados trabajo alguno en que se han utilizado redes neuronales para el problema de insolvencia empresarial.

2.2. MARCO TEORICO

En la presente investigación, los fundamentos teóricos se exponen en dos partes: un marco teórico general, en el que se describe y analiza lo que dicen los textos clásicos de finanzas sobre análisis financiero y la insolvencia

y; otro marco teórico con referente al análisis discriminante multivariante (ADM) seguido de las redes neuronales artificiales (RNA), en donde se consignan las principales teorías y la evidencia empírica sobre el tema de investigación. A partir de este último se adopta una determinada metodología para abordar el problema y se formula un modelo de redes neuronales artificiales de predicción.

Haciendo una revisión de las distintas acepciones que los autores plantean para la insolvencia empresarial o la quiebra, vemos diversidad en los trabajos extranjeros, aunque se puede detectar cierta evolución desde la identificación de situaciones de insolvencia presentes a la fecha de la evaluación, hacia objetivos predictivos de la situación de insolvencia., como podemos apreciar a continuación:

- Moyer, Charles, R., Mcguigan, James, R., y Kretlow, William, J. (2000), indican que la manifestación más extrema de una empresa con problemas es su quiebra, porque significa la desaparición de la empresa. La quiebra de una empresa puede estudiarse desde varios puntos de vista, los que más sobresalen son el económico y financiero, en el aspecto económico una empresa quiebra cuando obtiene un rendimiento de sus inversiones menor a su costo de capital. Es más común que la quiebra se perciba en un contexto financiero como insolvencia técnica extrema, insolvencia legal o quiebra. Una empresa es técnicamente insolvente extrema si es incapaz de cumplir sus obligaciones a medida que se vencen, aunque el valor de sus activos supere al de sus pasivos. Una empresa es legalmente insolvente si el valor registrado de sus activos es menor que sus pasivos.
- Stephen A. Ross (2006) señala que la quiebra financiera es una situación en la cual los flujos de efectivo de las operaciones de la empresa no son suficientes para hacer frente a las obligaciones

contraídas y la empresa se ve forzada a tomar acciones correctivas, que no habría tomado de tener un flujo de efectivo suficiente. Hace mención a una definición acerca de las quiebras financieras que puede explicarse si la vinculamos con la insolvencia, la cual es definida en la obra Black's Law Dictionary como:

“Incapacidad para pagar las deudas propias; falta de medios para pagar las deudas propias. Condición de los activos y pasivos de una mujer (o de un hombre) en la cual la disposición inmediata de los primeros será insuficiente para hacer frente a los segundos”.

Esta definición involucra dos temas generales: el capital y los flujos. La insolvencia basada en el capital ocurre cuando la empresa tiene un valor neto patrimonial negativo y, por ende, el valor de sus activos es inferior a de sus deudas. La insolvencia basada en los flujos se presenta cuando el flujo de efectivo operativo es insuficiente para pagar sus obligaciones en la fecha correspondiente y surge la incapacidad para el pago de las obligaciones de la empresa.

- Según Brealey y Myers (1998) sustentan que la insolvencia financiera se produce cuando los acuerdos de pago de deudas se rompen o se cumplen con dificultad. En ocasiones la insolvencia lleva a la bancarrota o a la quiebra de empresas que se producen cuando los accionistas ejercen su derecho de impago. Este derecho tiene un valor cuando una empresa se encuentra en problemas y la responsabilidad limitada permite a los accionistas salir de esta situación, dejando todos sus problemas a sus acreedores. Asimismo, señalan que la insolvencia financiera no termina siempre en quiebra, mientras pueda ir disponiendo de liquidez para pagar los intereses de su deuda y puedan disminuir las tensiones entre deudores y acreedores. La insolvencia financiera tiene costos cuando estos

conflictos de intereses afectan a las decisiones de inversión, financiación y producción.

- Por su parte, Van Horne (2003), señala que las compañías en angustia financiera tienen un número limitado de opciones. Sugiere que es preferible buscar algún tipo de solución con los acreedores de manera voluntaria, como la ampliación, la composición o hasta la liquidación. Al citar el caso norteamericano, el autor alude el capítulo 11 de la Ley de Quiebras y sostiene que es posible la reorganización de una compañía mediante la reducción de sus cargos fijos, sin embargo, para que se pueda aprobar un plan de reorganización, tiene que ser justo, equitativo y factible. Entonces, aún cuando las posibilidades de salvación de una empresa financieramente insolvente sean mínimas, existe la opción de recomponerla vía mecanismos financieros de mercado.
- Weston & Brigham (1982) señalan que en términos generales esto se produce cuando los ingresos no cubren los costos, lo que ocasiona la falta de capacidad para hacer frente el pago de obligaciones circulantes, derivándose en una reorganización y muchas veces en la bancarrota de la empresa.
- Gitman (2003), afirma que las empresas quiebran o fracasan debido a bajos rendimientos o resultados negativos, como también cuando la empresa es incapaz de obtener un rendimiento, que este por encima de su costo de capital. Un segundo tipo de fracaso es la insolvencia técnica, tiene lugar cuando una empresa es incapaz de pagar sus pasivos a su vencimiento, donde sus activos no han dejado de ser mayores que sus pasivos, pero es obvio que enfrenta una crisis de liquidez. El tercero y más grave tipo de fracaso, es la quiebra que ocurre cuando los pasivos de una empresa exceden el valor justo de

mercado de sus activos y posee un valor contable negativo, lo que ocasiona que los derechos de los acreedores no podrán ser satisfechos hasta en tanto los activos de la empresa no puedan ser liquidados a un precio mayor que su valor en libros. Aunque la quiebra es una forma obvia de fracaso, ésta y la insolvencia técnica reciben en los tribunales el mismo tratamiento. Ambas son consideradas por igual, como indicadores de fracaso financiero de la empresa.

- Graveline y Kokalari (2008) mencionan tres grupos de conceptos: dejar de pagar una deuda; reunir las condiciones previstas en la normativa vigente sobre quiebra; o tener una situación patrimonial precursora del fracaso futuro; si bien en el primer grupo definen la insolvencia como la incapacidad de atender obligaciones financieras a su vencimiento. En el segundo grupo se puede considerar a las empresas en quiebra o liquidadas a beneficio de los acreedores. Y un buen representante del tercer grupo sería Altman (1981), que define el fracaso como insolvencia técnica o en el sentido de capital consistente en falta de liquidez.
- Precisan otros autores, que la quiebra económica significa que los ingresos no cubren los costos o que la tasa de utilidad sobre los costos históricos de inversión es menor que el costo del capital de la empresa. Puede significar además, que las utilidades reales han descendido por debajo de los rendimientos esperados; y por otro, la quiebra financiera que está vinculada con la insolvencia, porque la empresa no puede hacer frente a sus obligaciones de corto plazo cuando vencen, aunque su activo total exceda de su pasivo total. Esto es insolvencia técnica.

- En el Perú, el aporte teórico más importante con relación al problema de investigación corresponde a Flint (1999), quién citando a Pedro Nuño sostiene que “la crisis de insolvencia es producto de tres fases del deterioro por los cuales atraviesa la empresa: Fase 1, primeros indicios o síntomas; Fase 2, intensificación de los problemas y; Fase 3, gestión de supervivencia e insolvencia”.

Los primeros indicios de una crisis se manifiestan en una reducción súbita de las ventas y la acumulación de inventarios. Generalmente las empresas ingresan en este período, luego de una etapa relativamente prolongada y agresiva de expansión lograda con alto endeudamiento. En esta primera fase, los especialistas recomiendan una reestructuración estratégica y financiera de la empresa, lo cual implica básicamente la adopción de un programa orientado a preservar, recolectar y movilizar de la mejor manera los recursos financieros y principalmente el efectivo, antes que las posibilidades de financiación disminuyan o desaparezcan.

Debido a la caída de la producción en esta segunda fase, se presentan frecuentes pérdidas en el balance de la empresa, haciéndose más urgente la demanda de efectivo. Ante la necesidad urgente de liquidez, las empresas se ven obligadas a vender activos - instalaciones esenciales y divisiones rentables del negocio-, recortar gastos en investigación y desarrollo, vender marcas y patentes, etc.

Si la situación continúa deteriorándose -señala Flint- la empresa ingresa a la tercera fase; es decir, se toma la decisión de proceder a la reestructuración por insolvencia, dentro del marco legal creado por el Decreto Legislativo N° 845, Ley de Reestructuración Patrimonial, que determina si la empresa puede reestructurarse o no. Si la empresa no tiene viabilidad o no alcanza un número de votos superior al 66,6 % se procede a su liquidación y posterior quiebra.

Para la norma vigente en el Perú, la insolvencia no es lo mismo que la quiebra, la insolvencia implica reconocer problemas, pero no implica que se encuentre en quiebra la cual es una suerte de “partida de defunción”⁴.

Como conclusión y para la presente investigación vemos tres grupos de conceptos diferentes. Una empresa es insolvente cuando:

1. Dejar de pagar una o varias de sus deudas, aunque sea de forma temporal.
2. Reúne las condiciones previstas en la normativa vigente sobre quiebra (o procedimientos similares). Una empresa está en quiebra si es incapaz de pagar sus deudas y presenta una solicitud de quiebra, de acuerdo con el Decreto Ley 26116 - LEY DE REESTRUCTURACION EMPRESARIAL.
3. Su situación patrimonial muestra un valor reducido en los activos o una escasez de liquidez que pueden desencadenar en fracaso.

Entendiéndose por solvencia a la capacidad financiera (capacidad de pago) de la empresa para cumplir sus obligaciones de vencimiento a corto plazo y los recursos con que cuenta para hacer frente a tales obligaciones, o sea una relación entre lo que una empresa tiene y lo que debe.

Para que una empresa cuente con solvencia, debe estar capacitada para liquidar los pasivos contraídos, al vencimiento de los mismos y demostrar también mediante el estudio correspondiente que podrá seguir una trayectoria normal que le permita conservar dicha situación en el futuro.

2.2.1. Análisis Financiero

El análisis financiero es definido como una técnica de evaluación del comportamiento operativo de una empresa, que facilita el diagnóstico de la situación actual y la predicción de cualquier acontecimiento futuro; a su vez

⁴ Documento de Trabajo N° 008-2000 - NDECOPÍ

está orientado hacia la consecución de objetivos preestablecidos, según Hernández (2005).

Los objetivos del análisis financiero se fundamentan en la medición del nivel de solvencia, liquidez, gestión, rentabilidad y, en general, la situación financiera actual de la empresa; por ello, el cumplimiento cabal de estos objetivos está sujeto a la calidad de la información contable y financiera utilizada para su aplicación. Para el desarrollo del análisis financiero se requiere del cálculo de razones o ratios financieros, que permiten realizar un diagnóstico de la situación económica y financiera del negocio. A juicio de Van Horne (2003), se utiliza una razón o ratio que relaciona entre sí los elementos de información financiera reflejados en los estados financieros y de esta forma, se logra evaluar la condición y desempeño financiero de la empresa.

Los ratios o razones financieras representan la base tradicional del análisis e interpretación de los estados financieros. Esta técnica propone el uso de estos coeficientes para la evaluación de la situación y evolución, tanto financiera como económica, de la empresa. Sin embargo, los ratios a pesar de ser un instrumento de uso frecuente, cuyo buen diseño y conocimiento permiten resolver algunos aspectos concretos para la toma de decisiones financieras, tienen una limitada capacidad para cuantificar de forma eficiente el éxito o fracaso financiero de una empresa.

El método de ratios precisamente persigue el acercamiento entre los hechos económicos y el rendimiento de la empresa para entender las relaciones más importantes que llevan al éxito, y así evitar en lo posible la complejidad de otros modelos, aunque sin olvidar tampoco las insuficiencias y debilidades que le son propias. Cabe indicar que ningún ratio hay que considerarlo aisladamente porque no son significativos por sí solos, pues todos ellos deben ser comparados con un patrón. Para obtener dicho patrón es necesario seleccionar primero a los ratios y definir cuales serán sus

objetivos (Westwick, 1987), también, la utilización de un razón debe estar basada sobre un conocimiento suficiente sobre su propia naturaleza y la significación de las relaciones que expresa para poder extraer una conclusión interesante.

Los ratios en general habían sido considerados como una herramienta para el análisis histórico y actual de la empresa. Sin embargo, a partir de hace casi cinco décadas también se ha orientado como una herramienta proyectiva (Beaver, 1966 y Altman, 1968). Una de las últimas propuestas más importantes para las que se utilizan los ratios, es la de servir estos como una base de datos aún más sintética que los estados financieros, reduciendo su redundancia (multicolinealidad) a través de otros métodos para llevar a cabo predicciones sobre el éxito o fracaso empresarial. Sin embargo, es importante considerar que los estados financieros, cuya característica básica es mostrar la situación de la empresa en un determinado momento, representan el primer punto de partida para calcular cualquier ratio. Por eso ciertos ratios requieren posteriormente ajustes más analíticos, pues no todos los componentes son fiables o están incluidos en los estados financieros.

Mientras en el análisis financiero tradicional o descriptivo los ratios representan el producto final del tratamiento de datos ("salida"), en los modelos de análisis financiero como multivariable o a través de las redes neuronales artificiales constituyen la materia prima ("entrada") que sirven para la toma de decisiones. La idea básica sobre el estudio de la tendencia y el comportamiento de los ratios de varias empresas es con el fin de poder identificarlos y utilizarlos con fines de predicción con base en sus características de mayor predominio (Bernstein 1999). Según algunos analistas financieros, esto permite detectar signos de deterioro observados en el comportamiento de los ratios, con una anticipación y claridad suficiente para tomar a tiempo iniciativas que eviten riesgos de insolvencia, suspensión de pagos y quiebras. Así, a los ratios se les utiliza como base de datos para

medir la rentabilidad, creación de valor, solvencia y liquidez, así evitar el fracaso financiero.

Con respecto a las limitaciones de los ratios, dada la gran cantidad de información financiera interna que produce la empresa, el método de ratios logra de forma simple, rápida y significativa generar información primaria reveladora y mucho más sintética para toma de decisiones, y hasta cierto punto, sin necesidad de recurrir a modelos matemáticos o estadísticos que, si no son bien utilizados, pueden llegar a ser instrumentos meramente teóricos que se alejan del carácter cambiante y pragmático que caracteriza a la empresa moderna.

Sin embargo, dicho método tiene insuficiencias y debilidades por la fácil manipulación de sus componentes (ya sea en el numerador y/o denominador). Además, también existen serios estudios que concluyen que el método de ratios “no es tan, o ni más simple” con respecto a los modelos matemáticos o estadísticos como se cree

Podemos destacar el hecho de que aunque actualmente existe poca vigencia de sus resultados, la trascendencia de su aporte al desarrollo de la teoría de la solvencia fue muy importante, ya que dichos trabajos representaron el primer intento para sistematizar un conjunto de procedimientos tendientes a describir el fracaso empresarial, lo que ha dado origen a la utilización con otros modelos más complejos (redes neuronales artificiales), pero al mismo tiempo más precisos que han dado buenos resultados, tal como expone Serrano y Gallizo (1997).

Muchos autores hacen referencia a la liquidez, pocos a la solvencia, pero algunos refieren el concepto de liquidez con el término de solvencia (Rubio, 2007); razón por la cual es necesario distinguir entre estas definiciones; pues, la liquidez implica mantener el efectivo necesario para cumplir o pagar los compromisos contraídos con anterioridad; mientras que la solvencia está

enfocada en mantener bienes y recursos requeridos para resguardar las deudas adquiridas, aún cuando estos bienes no estén referidos a efectivo, para una empresa tener liquidez significa cumplir con los compromisos y tener solvencia refleja la disponibilidad que posee para pagar esos compromisos; esto indica que para que una empresa presente liquidez es necesario que sea solvente con anticipación.

Sin embargo, para (Gitman, 2003), la liquidez se mide por la capacidad que posee una empresa para pagar sus obligaciones a corto plazo en la medida que se vencen. Este autor considera que la liquidez está referida a la solvencia de la posición financiera general de la organización, lo que se traduce en la facilidad que tiene la empresa para pagar sus deudas, no obstante, la liquidez es la capacidad inmediata de pago con la cual una empresa puede responder a sus acreedores; en tanto, la solvencia es la capacidad que tiene una empresa de responder en el corto plazo; cuya capacidad se refleja en la posesión de bienes que la empresa pueda disponer para cancelar los compromisos contraídos en el corto plazo. Para que una empresa sea solvente debe estar dispuesta a liquidar los pasivos contraídos al vencimiento de los mismos; además, debe demostrar que está en capacidad de continuar con una trayectoria normal que le permita mantener un entorno financiero adecuado en el futuro.

De este modo, la solvencia se refleja en la tenencia de cantidades de bienes que una empresa dispone para saldar sus deudas, pero sí para esa empresa no es fácil convertir esos bienes en efectivo para realizar sus cancelaciones, entonces no existe liquidez; por ello, es importante destacar que una empresa con liquidez es solvente pero no siempre una empresa solvente posee liquidez, desde el punto de vista económico, la liquidez está dada por la facilidad o dificultad de convertir un activo en dinero efectivo en forma inmediata y sin que sufra pérdida significativa de su valor, esto indica que mientras más fácil sea convertir un activo en efectivo más líquido será ese activo.

Una empresa que requiera cancelar los compromisos contraídos puede obtener recursos financieros más rápidamente mediante la conversión de sus inventarios y cuentas por cobrar en efectivo; puesto que, una empresa se considera líquida en la medida que posee una mayor proporción de sus activos totales bajo la modalidad de activos circulantes; estos últimos, constituyen todo el dinero que se encuentra disponible en efectivo al momento de elaborar el balance general de la empresa, como el dinero en bancos y caja chica, las cuentas por cobrar en el corto plazo y las colocaciones próximas a su vencimiento.

En razón de ello, los niveles de liquidez de una empresa se pueden determinar mediante la aplicación del análisis financiero, el cual relacionando los elementos de información financiera aportados por los estados financieros permite calcular ratios específicos que miden la liquidez y solvencia en una empresa, como la razón circulante y la razón prueba del ácido, que reflejan la capacidad de pago de la deuda circulante a corto plazo.

La razón circulante permite determinar la capacidad de la empresa para cancelar sus deudas en el corto plazo relacionando los activos circulantes con los pasivos circulantes. Se debe tener en cuenta que no siempre una razón circulante alta significa disponibilidad del efectivo requerido para las operaciones; ya que si el inventario no puede ser vendido o las ventas a crédito no son cobradas a tiempo para obtener el efectivo requerido, entonces el alto valor expresado por la razón circulante puede ser incierto (Brigham y Houston, 2006). Cabe indicar que una empresa al presentar problemas financieros, comienza a implementar medidas como cancelar sus compromisos con mayor lentitud o solicitar préstamos a la banca, de esta manera el pasivo circulante se incrementa más rápidamente y se ubica por encima del activo circulante, esto hace que la razón circulante comience a disminuir, lo cual resulta desfavorable para cualquier actividad empresarial;

pues, este es el indicador de liquidez y solvencia más confiable por expresar la tenencia de efectivo.

Por su parte, la razón prueba del ácido mide la suficiencia o no que posee la empresa para pagar en forma inmediata sus deudas en un momento dado; es similar a la razón circulante excepto que excluye las existencias, el cual es un activo menos líquido que el resto de los activos circulantes.

La importancia de determinar los ratios de liquidez en una empresa radica en que proporcionan la información acerca del nivel de liquidez que posee la misma; pues se puede presentar una situación de iliquidez, en la cual la organización no dispone de efectivo para la cancelación de sus obligaciones, cuya situación es contraproducente a los objetivos de la gestión financiera. La iliquidez acarrea consecuencias que implican limitaciones en la capacidad de pago de deudas y en el proceso de toma de decisiones financieras acertadas, disminución del nivel de actividades operativas, venta forzada de activos necesarios para el proceso productivo; aunado a que se puede producir una disminución en la rentabilidad, el no aprovechamiento de oportunidades de expansión, descontrol en las operaciones, inversiones y hasta puede llevar la empresa a la quiebra.

Los ratios de solvencia nos permiten determinar la capacidad de endeudamiento que tiene una empresa. Esto se traduce en que el nivel de deuda de una empresa está expresado por el importe de dinero que realicen personas externas a la empresa, llamadas acreedores, cuyo uso está destinado a la obtención de utilidades.

Entre los ratios de solvencia más destacados se incluyen: razón de endeudamiento total, razón de solvencia patrimonial, índice de capitalización y razón de cobertura del activo fijo.

La razón de endeudamiento total refleja la proporción de activos totales financiados por los acreedores de la empresa y mientras más alto sea su valor significa que los acreedores han aportado una gran suma de dinero para las operaciones empresariales esperando obtener beneficios. Mientras mayor sea este ratio, mayor será el financiamiento de terceros lo que refleja una mayor apalancamiento financiero y una menor autonomía financiera.

La razón de solvencia patrimonial, nos da una idea de que porcentaje de las inversiones totales han sido financiadas por deudas a terceros, pero desde otra perspectiva. Si este ratio es mayor a la unidad reflejara que el financiamiento de los accionistas y la utilidad que ha ido autogenerando las empresas, lo que refleja un mayor apalancamiento financiero y una menor autonomía financiera y mayor riesgo financiero tendrá la empresa.

El índice de capitalización, esta razón indica la porción de capital permanente que se financia con endeudamiento, desde el prestamista lo interpreta como el grado de protección que representa la inversión. Así aún cuando están muy interesados en saber que tan bien protegidos están sus préstamos en el caso de liquidación, están más interesados en no encontrarse mezclados en tal situación.

La razón de cobertura del activo fijo, mide la participación del capital ajeno en el financiamiento de largo plazo de la empresa (capital permanente de la empresa). Sin embargo, utilizar financiamiento tiene sus implicaciones sobre el riesgo y el rendimiento en cualquier empresa; puesto que la inversión de los accionistas será limitada aún cuando mantengan el control sobre su empresa, los acreedores visualizan el capital de los propietarios para disponer de un margen de seguridad, dado que corren con el mayor riesgo dentro de la empresa y por último, el rendimiento sobre el capital de los propietarios se puede incrementar o verse apalancado sí la empresa logra un mejor rendimiento sobre las inversiones financiadas por medio de préstamos en relación al interés pagado sobre los mismos.

Los ratios de gestión miden la rapidez con que ciertos activos se convierten en efectivo, es decir, miden el grado de liquidez y eficiencia de los activos que la empresa utiliza para apoyar sus ventas, es decir, son valores que muestran que tan efectivamente son manejados los activos totales, activos fijos, existencias, el proceso de cobranzas y costo de ventas/ventas.

Entre las razones de gestión o actividad se encuentran; plazo promedio de cobranza, plazo de inmovilización de existencias, rotación de activos totales, rotación de activos fijos, costo de ventas/ventas.

Plazo promedio de cobranza indica cuanto tiempo le lleva a la empresa cobrar sus cuentas por cobrar y se apoya en un promedio diario y por lo tanto, se supone que las ventas se reparten regularmente en un periodo. (Van Horne, 2003), señala que este indicador muestra el número de veces que las cuentas por cobrar han sido transformadas en efectivo reflejando el éxito de la empresa en el reembolso de sus ventas a crédito.

Plazo de inmovilización de existencias, con este ratio se obtiene una estimación del número de días que le lleva a la empresa vender o consumir sus existencias. (Jerry Viscione, 1991) afirma que esta razón es empleada como guía para determinar si la empresa vende o consume sus existencias rápida o lentamente.

La rotación de activos totales indica la capacidad que posee una empresa para la utilización de sus activos totales en la obtención de ingresos; es decir; está referida a la eficiencia en el manejo de activos para generar mayores ventas. Mientras más alta es la rotación de activos totales mayor resulta el nivel de eficiencia en el uso que hace la empresa de los bienes y derechos que posee.

De igual manera, la rotación de activos fijos expresa la eficiencia de la empresa para generar ingresos a través de la inversión que realice en

activos fijos (edificaciones, instalaciones, maquinarias, equipos). Es un valor que expresa el número de veces que la empresa renueva sus activos fijos en un año; mientras mayor resulte el valor de este indicador, implica una utilización más eficiente de los bienes que posee la organización.

Costo de ventas/ventas con este ratio se puede ver con más claridad la proporción en que los ingresos generados por la empresa a través de la ventas, han sido absorbidos por los costos aplicados en la producción de los bienes o servicios.

La rentabilidad constituye el resultado de las acciones gerenciales, decisiones financieras y las políticas que se implementan en una organización. Fundamentalmente, la rentabilidad está reflejada en la proporción de utilidad o beneficio que aporta un activo, dada su utilización en el proceso productivo, durante un período de tiempo determinado; aunado a que es un valor porcentual que mide la eficiencia en las operaciones e inversiones que se realizan en las empresas. Mediante la aplicación de ratios financieros que muestran los efectos de gestionar en forma efectiva y eficiente los recursos disponibles, arrojando cifras del rendimiento de la actividad productiva y determinando si ésta es rentable o no. Entre estos indicadores se encuentran la rentabilidad sobre el capital propio (ROE), la rentabilidad sobre la inversión (ROA) y la rentabilidad sobre las ventas.

La rentabilidad sobre el capital propio (ROE) muestra, en términos porcentuales, las ganancias generadas dado el capital aportado por los accionistas o propietarios del negocio.

La rentabilidad sobre la inversión (ROA) está enfocado en medir la efectividad con que se utilizan los activos necesarios para el proceso de producción; esto se traduce en la proporción de las ganancias obtenidas por la empresa dada su inversión en activos totales (activos circulantes + activos fijos).

Por su parte, la rentabilidad sobre las ventas es un indicador financiero que expresa la utilidad que obtiene la organización en relación con sus ventas e indica el costo de las operaciones y las fluctuaciones que pueda sufrir tanto el precio como el volumen de los productos. Así, los ratios de rentabilidad muestran los retornos netos obtenidos por las ventas y los activos disponibles, midiendo la efectividad del desempeño gerencial llevado a cabo en una empresa.

Indica Jerry A. Viscione (1991), que el propósito de usar ratios en los análisis de los estados financieros es reducir la cantidad de datos a una forma práctica y darle un mayor significado a la información, este propósito no se logra si se calculan demasiados ratios; el analista debe saber cual combinación de ratios es la más apropiada para una situación específica, también debe saber que un ratio solo significa muy poco y su valor se deriva de su uso con otras ratios y de su comparación con alguna otra.

Los ratios pocas veces proporcionan respuestas concluyentes. En vez de ello, inducen a la persona que toma la decisión hacer las preguntas debidas y algunas veces dan las pistas de posibles áreas de fortaleza y debilidad. El analista prudente usará los ratios para señalar ciertas áreas que merece mayor atención.

Según Pedro Franco (2005), los estados financieros son una importante y relevante fuente de información para la toma de decisiones, para el establecimiento de las políticas y para el diseño de las estrategias futuras de la empresa. Proporcionan información de tal manera que al momento de analizarla, se tiene conocimiento de la magnitud de su nivel de gastos; de los flujos de salida del dinero que deberán realizar en el futuro mediano o inmediato; del nivel de la inversión en maquinaria y sus fuentes de financiamiento; del resultado económico de la gestión de la empresa en un determinado periodo; de la estructura de las deudas con terceros, de la

gestión de la gerencia y otros aspectos que influyen las decisiones de los usuarios de dicha información financiera.

Sin embargo, los ratios a pesar de ser un instrumento de uso frecuente, cuyo buen diseño y conocimiento permiten resolver algunos aspectos concretos para la toma de decisiones financieras, tienen una limitada capacidad para cuantificar de forma eficiente el éxito o fracaso de una empresa. Mientras este análisis tradicional representa el producto final del tratamiento de datos.

Como podemos apreciar los ratios financieros más destacados y utilizados frecuentemente para llevar a cabo el análisis financiero, se clasifican en los siguientes: ratios de liquidez, solvencia, gestión o actividad, y de rentabilidad. Sirve como datos de entrada para otros métodos de entrada.

Diversos métodos estadísticos se han desarrollado para dar solución al problema de insolvencia empresarial como modelos de análisis predictivo, donde las razones o ratios financieros constituye la materia prima del análisis multivariante.

2.2.2. Modelos Estadísticos

A la par con el desarrollo teórico orientado a resaltar la importancia del problema de la insolvencia financiera, también se han producido avances en la búsqueda de evidencia empírica sobre los factores específicos que la determinan, lo que ha dado lugar a la formulación de diversos tipos de Modelos de Predicción de la Insolvencia Empresarial. Al respecto, el Instituto Federal de Especialistas de Concursos Mercantiles -IFECOM- de México⁵, sostiene que “el interés de los profesionales de las finanzas por contar con modelos de predicción de la insolvencia en las empresas, ha llevado a varios expertos en la materia en todo el mundo, a desarrollar modelos matemático-

⁵ Véase “Modelos de Predicción de la Insolvencia Empresarial” y “El Análisis Financiero....” en las páginas web: www.ifecom.cjf.gob.mx & www.cursos.uexternado.Edu.Co.

financieros que permiten diagnosticar y predecir con cierta anticipación la insolvencia financiera empresarial". Entre los más destacables tenemos son, los trabajos de Altman (1968), que fueron desarrollados bajo un nuevo entorno tecnológico cuando se contó con un uso más significativo de las computadoras y el grado de maduración de las escuelas estadísticas repercutió directamente en el desarrollo de las técnicas multivariadas. Por lo que se consiguió resultados sorprendentes al aprovechar las ventajas del análisis tradicional de ratios sin fundamentos simplistas y combinándolas con las técnicas estadísticas más sofisticadas, como es el caso del análisis discriminante y otros modelos más complejos, para determinar la insolvencia de la empresa; especialmente los modelos Logit y Probit.

La justificación del análisis multivariante como complemento o sustituto del análisis tradicional a través de ratios y dentro del análisis financiero contemporáneo, parte del hecho de que determinar el éxito o fracaso de una empresa constituye un tema complejo. Esto por interactuar varios factores simultáneamente y combinados entre sí, el problema en realidad radica en determinar el peso específico o la contribución marginal que tienen cada uno de esos factores dentro de un análisis financiero integral con fines predictivos. Estos factores se expresan como variables explicativas o independientes dentro de ciertos modelos econométricos con base en funciones lineales.

Dentro del campo de la investigación sobre la relación entre los ratios y los modelos multivariados, la predicción de quiebras ha sido el tema central al que se han dirigido la mayoría de los trabajos empíricos. Esto se debe en parte al hecho de haberse alcanzado la idea de la diferenciación de los ratios entre los diferentes períodos contables, lo cual representó en su momento para esta línea de estudio la denominada: "etapa descriptiva". Posteriormente, la idea que se desarrolló fue la significancia de cada ratio (posibilidad de explicación de la quiebra) así como la capacidad predictiva de los ratios más relevantes, lo cual dio origen a la denominada: "etapa

predictiva". En esta segunda etapa es cuando surgen los modelos univariados con los trabajos pioneros de Beaver (1966, 1968), donde inició sus estudios empíricos tendiendo a "descomponer" los ratios a través de métodos estadísticos avanzados con el fin de aplicarlos como una técnica que permitiera determinar la solvencia y la liquidez real de las empresas para posteriormente poder predecir una quiebra. Para esto utilizó el análisis univariable, que tiene como objetivo principal la utilización por separado de una o varias variables independientes para explicar una variable dependiente, estableciendo que era posible utilizar ratios para distinguir entre empresas en quiebra y empresas sin quiebra en una medida mucho mayor que la permitida por la predicción aleatoria.

Según Bizquerra (1989, p. 4) presenta un análisis multivariable con el que se llega a la máxima sofisticación en el proceso de datos y que puede sintetizarse en los siguientes tres tipos: a) El análisis exploratorio de los datos o estadística descriptiva univariable: consiste en analizar una o cada una de las variables independientes por separado. b) El análisis o estadística bivariado: su objetivo consiste en buscar la relación entre pares de variables independientes. c) El análisis multivariable: su objetivo es analizar simultáneamente tres o más variables independientes métricas (ratios) a través de funciones lineales de dependencia.

2.2.2.1. Análisis Discriminante Múltiple

El análisis discriminante múltiple cuenta con amplias aplicaciones y es utilizado para clasificar a distintas entidades en grupos, o poblaciones, alternativos a partir de los valores de un conjunto de variables sobre las entidades a los que se pretende clasificar. Cada entidad puede pertenecer a un solo grupo. La pertenencia a uno u otro grupo se introduce en el análisis mediante una variable categórica que toma tantos valores como grupos existentes y juega el papel de variable dependiente no métrica y la asignación de cada elemento de la muestra a una de ellas será función de variables independientes métricas, combinadas linealmente. El análisis

discriminante buscará aquella combinación lineal de variables independientes que permitirá conformar grupos de elementos que presenten simultáneamente una varianza intra-grupos mínima y una varianza intergrupos máxima.

La relación que se estudia en este ámbito presenta la siguiente forma genérica:

$$y = f(x_1, x_2, \dots, X_m) \quad \text{y no métrica, } x_i \text{ métricas}$$

Cada vez es más frecuente distinguir dos posible fines de aplicación de la técnica de análisis discriminante: uno descriptivo y otro predictivo. El primer caso se emplea con la finalidad de entender cómo la combinación lineal de variables independientes permite discriminar entre los distintos grupos definidos en la variable dependiente. En el segundo se utilizarán los valores de las variables independientes para adscribir a cada nueva entidad al grupo o categoría que le corresponda.

En muchos casos, la variable dependiente consta de dos grupos o clasificaciones, por ejemplo solvente e insolvente, en otras situaciones, se incluyen más de dos casos, como una clasificación de tres grupos que comprenda clasificaciones bajas, medias y altas. El análisis discriminante tiene la capacidad de tratar tanto dos grupos como grupos múltiples. Cuando se incluyen dos clasificaciones, la técnica es conocida como análisis discriminante de dos grupos. Cuando se identifican tres o más clasificaciones, la técnica es conocida como análisis discriminante múltiple

A partir de una variable dependiente cualitativa y un conjunto de una o más variables independientes cuantitativas, Se aplica para fines explicativos y predictivos. En la utilización explicativa se trata de determinar la contribución de cada variable clasificadora a la clasificación correcta de cada uno de las entidades. En una explicación predictiva, se trata de determinar el grupo al

que pertenece una entidad para el que se conoce los valores que toman las variables clasificadoras.

Es usado principalmente, para clasificar o hacer predicciones en problemas donde la variable dependiente es categórica y no numérica, este tipo de variable es de un tipo especial empleadas en las ecuaciones de regresión múltiple, cuando aparecen como explicativas permiten desde probar la estabilidad de los coeficientes de una regresión, hasta introducir aspectos cualitativos en la misma y pueden tomar dos o más valores no obstante el caso más común es el que empleo el cero y el uno, en este caso se conoce como variable dicotómica.

$$Y = \begin{cases} 0 = \text{insolvente} \\ 1 = \text{solvente} \end{cases}$$

Este método implica obtener un valor teórico, es decir, una combinación lineal de dos o más variables independientes que discrimine mejor entre los grupos definidos a priori. La discriminación se lleva a cabo estableciendo las ponderaciones del valor teórico para cada variable de tal forma que maximice la varianza entre - grupos frente a la varianza intra – grupos. La combinación lineal para el análisis discriminante, también conocida como función discriminante. Supone que si se tienen n entidades⁶ para las que se conocen k variables explicativas, y se observa que n_1 de ellas pertenece a un grupo (1) y n_2 a otro grupo (2), donde: $n_1 + n_2 = n$; es posible construir una función lineal de las k variables que puede usarse para predecir si una nueva observación pertenece a un grupo u otro con una probabilidad determinada. La función lineal general se define como sigue:

$$Z = \lambda_0 + \sum_{i=1}^k \lambda_i x_i$$

⁶ Las entidades pueden referirse a individuos, instituciones, etc.

En este contexto, el análisis de función discriminante se emplea para determinar cuál o cuales variables contribuyen a discriminar entre dos o más grupos que se observan en la práctica.

El problema de la función de análisis discriminante desde el punto de vista del análisis de varianza consiste en responder a la pregunta de si dos o más grupos son significativamente diferentes uno de otro respecto a la media de una variable en particular. Debe tenerse presente que si la media de una variable es significativamente diferente en varios grupos, puede decirse que esta variable discrimina entre grupos.

La función discriminante puede verse como un caso de análisis de regresión lineal múltiple⁷, cuya ventaja, es la reducción de las dimensiones del espacio en análisis, es decir, se reduce el número de variables dependientes a $G - 1$ dimensiones, donde G es el número de grupos determinados a priori. Esto es muy útil en el contexto de la predicción de quiebras, ya que se parte de dos grupos (solventes e insolventes), el análisis se transforma a la forma más simple: una dimensión.

En el caso de una única variable explicativa, la prueba final de significancia de si esta variable discrimina o no entre grupos es una prueba F , que es básicamente una razón de las varianzas entre grupos sobre el promedio de las varianzas dentro de los grupos. Si la varianza entre grupos es significativamente mayor, deberá haber diferencias significativas entre las medias.

Para el caso de más de una variable, se busca determinar cuál o cuáles de ellas contribuyen a la discriminación entre grupos. En este caso, se tiene una matriz de varianzas y covarianzas. Puede compararse las matrices con una

⁷ Posterior al año 1936, el análisis de función discriminante para dos grupos se conoce también como Análisis Discriminante lineal de Fisher.

prueba F multivariable, para determinar si hay o no diferencias significativas en las medias entre grupos.

Si se codifican los dos grupos como 1 y 2, y se emplea tal variable como dependiente en un análisis de regresión lineal múltiple, pueden obtenerse resultados similares a los que se obtendrían de un análisis discriminante. En general, en el caso de dos grupos se ajusta una ecuación lineal del tipo:

$$D = u_1X_1 + u_2X_2 + \dots + u_kX_k$$

La interpretación de estos resultados es similar a la de un modelo de regresión múltiple. El problema planteado es la obtención de los coeficientes de ponderación u_j . Si consideramos que existen n observaciones, podemos expresar la función discriminante para las n observaciones:

$$D_i = u_1X_{1i} + u_2X_{2i} + \dots + u_kX_{ki} \quad i = 1, 2, \dots, n$$

Así, D_i es la puntuación discriminante correspondiente a la observación i -ésima. Expresando las variables explicativas en desviaciones respecto a la media, D_i también lo estará. La anterior relación se puede expresar en forma matricial para el conjunto de las observaciones:

$$\begin{pmatrix} D_1 \\ D_2 \\ \dots \\ D_n \end{pmatrix} = \begin{pmatrix} X_{11} + X_{21} + \dots + X_{k1} \\ X_{12} + X_{22} + \dots + X_{k2} \\ \dots \quad \dots \quad \dots \quad \dots \\ X_{1n} + X_{2n} + \dots + X_{kn} \end{pmatrix} \begin{pmatrix} u_1 \\ u_2 \\ \dots \\ u_n \end{pmatrix}$$

O, en notación matricial más compacta:

$$d = X u$$

La variabilidad de la función discriminante es decir, la suma de los cuadrados de las variables discriminantes en desviaciones respecto a su media se puede expresar de la siguiente forma:

$$d' d = u X' X u$$

La matriz cuadrática $X'X$, al estar expresada las variables en desviaciones respecto a la media, es la matriz de suma de cuadrados y productos cruzados (SCPC) total de las variables X . En el análisis multivariante de la varianza se calculan también matrices de ese tipo. La diferencia radica en que, en el análisis discriminante, estas matrices se obtienen para las variables explicativas, mientras que en el análisis multivariante de la varianza se obtienen para las variables dependientes. Esta matriz se puede descomponer en la matriz de la SCPC entre – grupos y la SPPC residual o intra - grupos. La descomposición de $X'X$ puede expresarse así:

$$X'X = T = F + W$$

Donde T , F y W son las matrices de SCPC total, entre – grupos e intra – grupos respectivamente.

$$d'd = u'Tu = u'Fu + u'Wu$$

En la expresión anterior T , F y W se pueden calcular con los datos muestrales, mientras que los coeficientes u_i están por determinar. Para su estimación, Fischer utilizó el siguiente criterio:

$$\text{Maximización de } = \frac{\text{Variabilidad entre – grupos}}{\text{Variabilidad intra - grupos}}$$

Con este criterio se trata de determinar el eje discriminante de forma que las distribuciones proyectadas sobre el mismo estén lo más separadas posible entre sí (mayor variabilidad entre grupos) y, al mismo tiempo, que cada una de las distribuciones esté lo menos dispersa (menor variabilidad dentro de los grupos).

$$\text{Maximización de } \lambda = \frac{u'Fu}{u'Wu}$$

Se puede apreciar, que el término (entre – grupos) sea lo mayor posible en detrimento del segundo término (intra – grupos).

Los coeficientes u_1, u_2, \dots, u_k (normalizados) que se obtienen en el proceso de maximización de λ puede contemplarse como un conjunto de cosenos que definen la situación del eje discriminante. Para esta interpretación, la normalización a que nos referimos es que la suma de cuadrados sea la unidad.

Las puntuaciones discriminantes son pues los valores que se obtienen al dar los valores X_1, X_2, \dots, X_k en la ecuación de la función discriminante, y se corresponden con los valores obtenidos al proyectar cada punto del espacio K – dimensional de las variables originales sobre el eje discriminante.

Los centros de gravedad o centroides (es decir, el vector de medias) son los estadísticos básicos que resumen la información sobre los grupos. Las denominaciones que utilizaremos para designar a los centroides de los grupos I y II son las siguientes.

$$\bar{X}_I = \begin{pmatrix} \bar{X}_{1,I} \\ \bar{X}_{2,I} \\ \dots \\ \bar{X}_{k,I} \end{pmatrix} \quad \bar{X}_{II} = \begin{pmatrix} \bar{X}_{1,II} \\ \bar{X}_{2,II} \\ \dots \\ \bar{X}_{k,II} \end{pmatrix}$$

Sustituyendo en la ecuación de la función discriminante X_1, X_2, \dots, X_k por los elementos del vector \bar{X}_I , se obtiene que:

$$\bar{D}_I = u_1 \bar{X}_{1,I} + u_2 \bar{X}_{2,I} + \dots + u_k \bar{X}_{k,I}$$

Procediendo de forma análoga en el grupo II, se obtiene:

$$\bar{D}_{II} = u_1 \bar{X}_{1,II} + u_2 \bar{X}_{2,II} + \dots + u_k \bar{X}_{k,II}$$

El punto de corte discriminante C se calcula promediando \bar{D}_I y \bar{D}_{II} , es decir:

$$C = \frac{\bar{D}_I + \bar{D}_{II}}{2}$$

El criterio para clasificar al individuo i es el siguiente:

Si $D_i < C$, Se clasifica al individuo i en el grupo I

Si $D_i > C$, Se clasifica al individuo i en el grupo II

En general, cuando se aplica el análisis discriminante se le resta el valor de C a la función. De esta forma, la función discriminante viene dada por:

$$D - C = u_1 X_1 + u_2 X_2 + \dots + u_k X_k$$

Utilizando la ecuación anterior, se clasifica a un individuo en el grupo I si $D_i - C < 0$, y en el grupo II, en otro caso.

Existe una forma alternativa a la utilización de la función discriminante, que consiste en construir funciones discriminantes para cada grupo, basadas también en el criterio para la obtención de la función discriminante. Estas funciones a las que denominaremos F_I y F_{II} , tiene la siguiente estructura:

$$F_I = a_{I,1} X_1 + a_{I,2} X_2 + \dots + a_{I,k} X_k - C_I$$

$$F_{II} = a_{II,1} X_1 + a_{II,2} X_2 + \dots + a_{II,k} X_k - C_{II}$$

Cuando se utilizan estas funciones, se clasifica a una entidad en el grupo para el que la función F_j sea mayor. Además, en buena parte en los programas de análisis multivariante se suministran estas funciones.

2.2.2.2. Contraste de significación y evaluación de la bondad del ajuste

Con los contrastes de significación que se realizan en el análisis discriminante con dos grupos se trata de dar respuesta a tres preguntas diferentes:

- ¿Se cumple la hipótesis homoscedasticidad del modelo?
- ¿se cumple la hipótesis de normalidad?
- ¿Difieren significativamente las medias poblacionales de los dos grupos?

Para el contraste de la homoscedasticidad se utiliza el estadístico de Barlett-Box, denominado en el programa PASW Statistics Base, M de Box

obteniéndose la aproximación a través de la distribución F. El análisis de normalidad en el caso multivariante se realiza variable a variable, dada la complejidad de hacerlo conjuntamente, se utiliza el estadístico de Wilks. La respuesta que se da a la pregunta c es crucial para la realización del análisis discriminante, si fuera el caso de ser negativo carecería de interés de continuar con el análisis, ya que significaría que las variables introducidas como variables clasificadoras no tienen una capacidad discriminante significativa.

La hipótesis nula y la alternativa para dar respuesta a la pregunta c es la siguiente;

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

El contraste de la hipótesis anterior se puede realizar específicamente mediante el estadístico T^2 .

Como medida de evaluación de la bondad del ajuste se utiliza el coeficiente *eta cuadrado* (χ^2), que es el coeficiente de determinación obtenido al realizar la regresión entre la variable dicotómica, que indica la pertenencia al grupo, y las puntuaciones discriminantes. A la raíz cuadrada de este coeficiente se le denomina correlación canónica. La expresión alternativa de correlación canónica es la siguiente:

$$\chi = \sqrt{\frac{\Lambda}{1 + \Lambda}}$$

2.2.3. Inteligencia Artificial

A diferencia de la filosofía y la psicología, que tratan de entender cómo funciona la inteligencia en abstracto, la Inteligencia Artificial (IA) es un intento por descubrir y aplicar los aspectos de la inteligencia humana que pueden ser simulados mediante construcciones artificiales. Se observa que hasta en las etapas tempranas de su desarrollo, la Inteligencia Artificial (IA) ha presentado productos sorprendentes en sus aplicaciones (Stuart et al., 1995).

Hoy en día, el campo de la Inteligencia Artificial (IA) enmarca varias subáreas tales como los sistemas expertos, la demostración automática de teoremas, el juego automático, el reconocimiento de la voz y de patrones, el procesamiento del lenguaje natural, la visión artificial, la robótica, las redes neuronales, etc. (Castillo et al., 1998).

La inteligencia artificial (IA) surge así como una disciplina cuyo objetivo es proveer técnicas para el desarrollo de programas capaces de simular la inteligencia que utilizan los humanos para solucionar problemas en una gran cantidad de dominios (Krishnamoorthy et al, 1996), por lo que la IA provee un conjunto de formalismos que pueden representar los problemas, las herramientas y técnicas para resolverlos. Según diversos autores (Krishnamoorthy et al, 1996); Newell, (1969) las actividades esenciales asociadas con la inteligencia son:

- Responder de manera flexible a una gran variedad de situaciones.
- Dar sentido a los mensajes contradictorios y/o ambiguos.
- Reconocer la importancia relativa de los diferentes elementos de la situación problemática planteada.
- Encontrar similitudes entre situaciones, sin importar las diferencias que las separan.
- Encontrar las diferencias entre situaciones, sin importar lo similares que puedan parecer.

La Inteligencia Artificial es multidisciplinar y se apoya en los conceptos y técnicas de otras disciplinas, tales como: la Informática, la Ingeniería, la Sociología, la Ciencia del Comportamiento, la Psicología Cognoscitiva, la Investigación Operativa, la Economía, la Teoría General de Sistemas, etc. (Sánchez Tomás, 1993). En el momento actual la Inteligencia Artificial se aplica a numerosas actividades humanas, y como líneas de investigación más explotadas destacan el razonamiento lógico, la traducción automática y

comprensión del lenguaje natural, la robótica, la visión artificial y, especialmente, las técnicas de aprendizaje y de ingeniería del conocimiento. Estas dos últimas ramas son las más directamente aplicables al campo de las finanzas pues, desde el punto de vista de los negocios, lo que interesa es construir sistemas que incorporen conocimiento y, de esta manera, sirvan de ayuda a los procesos de toma de decisiones en el ámbito de la gestión empresarial.

En el ámbito de las finanzas el estudio de la solvencia implica una investigación selectiva dentro de un espacio de alternativas inmenso pues, no existe un procedimiento que conduzca de forma inequívoca a la solución óptima. Por lo tanto, la selección ha de estar basada en reglas prácticas o heurísticas, debiendo fijarse también un criterio de suficiencia para determinar cuando las soluciones encontradas son satisfactorias.

Ese análisis heurístico se ha implementado tradicionalmente a través de la aplicación de técnicas estadísticas, tales como el análisis discriminante lineal o los diversos modelos de variable de respuesta cualitativa (logit, probit, etc.). Sin embargo todas estas técnicas presentan limitaciones, pues parten de hipótesis más o menos restrictivas, que por su propia naturaleza la información económica, y en especial los datos extraídos de los estados financieros de las empresas, no van a cumplir, perjudicando así los resultados. Estas hipótesis vienen referidas a las propiedades de distribución de las variables de partida, las cuales han sido ampliamente estudiadas en trabajos empíricos como el de Watson (1990), Martikainen et al., (1995), o Lau et al. (1995), entre otros.

La aplicación de técnicas procedentes del campo de la Inteligencia Artificial surge como un intento de superar esta limitación, pues estas últimas no parten de hipótesis preestablecidas y se enfrentan a los datos de una forma totalmente exploratoria, configurándose como procedimientos estrictamente no paramétricos, elaborando programas capaces de generar conocimiento a

través de un proceso consistente en anticipar patrones en los datos, en una fase posterior, usar ese conocimiento para realizar inferencias sobre nuevos datos, las arquitecturas de Redes Neuronales Artificiales van encaminadas a este propósito.

2.2.4. Redes Neuronales Artificiales (RNA)

2.2.4.1. El Modelo Biológico

Una neurona es una célula viva que consta de un cuerpo celular relativamente esférico de 5 a 10 micrones de diámetro, denominado soma, del que se desprende una rama principal o axón y varias ramas más cortas llamadas dendritas. A su vez, el axón presenta ramas en torno a su punto de arranque, y se ramifica extensamente en su extremo.

Una de las características que diferencia a las neuronas de otras células, es la capacidad de comunicarse, denominada en el campo de la biología como sinapsis neuronal. Las dendritas y el cuerpo celular reciben señales de entrada, el cuerpo celular las combina e integra y emite señales de salida. Estas señales pertenecen a dos naturalezas:

- **Química:** La señales que se transmiten entre los terminales axónicos y las dendritas se realiza mediante moléculas de sustancias químicas llamadas neurotransmisores que fluyen a través de unos contactos denominados sinapsis, estando estos localizados entre los terminales axónicos y las dendritas de las neuronas siguientes, dejando entre estos un espacio sináptico entre 50 y 200 Å.
- **Eléctrica:** La señal generada por la neurona, que se transporta a lo largo del axón es un impulso eléctrico La neurona contiene interiormente un líquido cuya composición difiere de la del líquido del exterior, con una concentración diez veces mayor de iones potasio, mientras que el medio externo contiene diez veces más iones sodio.

Esta diferencia de concentraciones genera una diferencia de potencial entre el interior y el exterior de la membrana celular del orden de los 70 mV que se conoce con el nombre de potencial de reposo. La recepción de neurotransmisores actúa acumulativamente bajando, o subiendo, ligeramente el valor del potencial de reposo. El resultado de todo esto es la emisión por parte de la neurona, de trenes de impulsos cuya frecuencia varía en función de la cantidad de neurotransmisores recibidos. Existen dos tipos de sinapsis:

Excitadoras (cuyos neurotransmisores provocan disminución de potencial en la membrana celular, facilitando la generación de impulsos) e **Inhibidoras** (cuyos neurotransmisores tienden a estabilizar el potencial, dificultando la emisión de trenes de impulsos).

El cerebro resulta ser un complejo sistema de procesamiento, no lineal, masivamente paralelo, y adaptativo, pero además es extraordinariamente eficiente desde un punto de vista energético. Según Haykin (1999) el cerebro emplea 10^{-16} Julios para ejecutar una operación por segundo, mientras que una computadora actual emplea unos 10^{-6} , diez órdenes de magnitud más.

Características	Computadora	Cerebro Humano
Velocidad de proceso	= 10^9 seg. (1000 MHz)	= 10^2 seg. (100 Hz)
Estilo de procesamiento	secuencial	paralelo
Número de procesadores	pocos	10^{11} - 10^{14}
Conexiones	pocas	10,000 por procesador
Almacenamiento del conocimiento	direcciones fijas	distribuido
Tolerancia a fallos	nula	amplia
Tipo de control de proceso	Centralizado	Auto - organizado

Tabla 1.1: Comparación entre el cerebro humano y una computadora.

Las Redes Neuronales Artificiales comprende una vasta gama de algoritmos inspirados, en mayor o menor grado, en los sistemas neuronales encontrados en los organismos biológicos y en la función que estos cumplen en los procesos de aprendizaje y adaptación típicos de los seres vivos, notoriamente del ser humano.

Una definición del concepto de Red Neuronal Artificial es la encontrada en el trabajo de Hetch (1990), cita tomada a su vez de Pandya and R. B. Macy (1996):

“Una red neuronal es una estructura de procesamiento de información distribuida y paralela que consiste en unidades de procesamiento, que pueden poseer memoria propia y realizar operaciones de procesamiento de información localmente, interconectadas vía canales de señal unidireccionales denominados conexiones. Cada unidad de procesamiento tiene una única conexión de salida que bifurca en una cantidad arbitraria de conexiones, cada una cargando la misma señal - la salida de la unidad de procesamiento. Dicha salida puede ser de cualquier tipo matemático deseado. El procesamiento de la información que transcurre en cada unidad de procesamiento puede ser definido arbitrariamente con la restricción de que debe ser completamente local; esto significa que sólo puede depender de los valores actuales de las señales de entrada a la unidad de procesamiento a través de sus conexiones de entrada y los valores almacenados en la memoria local de dicha unidad de procesamiento”.

Otras definiciones válidas son, las que plantea ARPA⁸ en su Neural Network Study (DARPA, 1988) en la que una: “red neuronal artificial es un sistema compuesto de muchos elementos simples de procesamiento operando en paralelo y cuya función es determinada por la estructura de la red, fuerza de las conexiones y el procesamiento llevado a cabo en los elementos individuales o nodos”. Por su parte, Kohonen (1998) plantea que: “una red neuronal artificial es un conjunto de redes interconectadas masivamente en

⁸ Advanced Research Projects Agency (ARPA), creada por la directiva 5105.15 del Department of Defense (DOD) de los Estados Unidos. Su responsabilidad principal es el desarrollo de proyectos avanzados en los campos de investigación y desarrollo que designe individualmente el Departamento de Defensa. Antes de 1993 su nombre era DARPA (Defense Advanced Research Projects Agency). <http://www.darpa.mil>. Consultado el 08/11/2005

paralelo de elementos simples, usualmente adaptativos, y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico”. Existen también otros estudiosos que han desarrollado definiciones similares, como Haykin (1999) y Gurney (1995).

También existen definiciones que se aproximan más a los modelos biológicos, como la de Zurada (1992), quien plantea que “una red neuronal artificial, es un sistema celular físico que puede adquirir, almacenar y utilizar el conocimiento experimental”. Independientemente de las diferencias en las distintas definiciones, el elemento clave del paradigma de las redes neuronales artificiales son las estructuras novedosas del sistema de procesamiento de la información. La neurona artificial pretende simular las características más importantes de las neuronas biológicas. Cada una se caracteriza en un instante cualquiera por un estado de activación que transforma el estado actual en una señal de salida. En los sistemas biológicos el proceso de cambio de estado es un proceso asincrónico, mientras que en las neuronas artificiales este proceso es sincrónico.

La neurona artificial pretende simular las características más importantes de las neuronas biológicas. Cada una se caracteriza en un instante cualquiera por un estado de activación que transforma el estado actual en una señal de salida. En los sistemas biológicos el proceso de cambio de estado es un proceso asincrónico, mientras que en las neuronas artificiales este proceso es sincrónico. Existen tres tipos de neuronas:

- **De Entrada:** son aquellas que reciben estímulos externos, relacionadas con el aparato sensorial y cumplen la función de ingreso de información al sistema.
- **Ocultas:** Son aquellas que se encargan de procesar la información ingresada. Se genera algún tipo de representación interna de la información y se la procesa.

- **De Salida:** Una vez finalizado el período de procesado, la información llega a las unidades de salida, cuya misión es dar la respuesta del sistema.

Esta visión representa al cerebro humano como una máquina, que ostenta ciertas cualidades de procesamiento de la información que la ciencia intenta imitar Nilson, (2001).

2.2.4.2. Neurona Artificial

El objetivo de una neurona artificial es recibir las entradas de las neuronas vecinas y calcular un valor de salida que es enviado todas las neuronas conectadas con ella. Todas las neuronas que componen la red se hallan en un determinado estado, pudiendo tomar valores continuos o discretos.

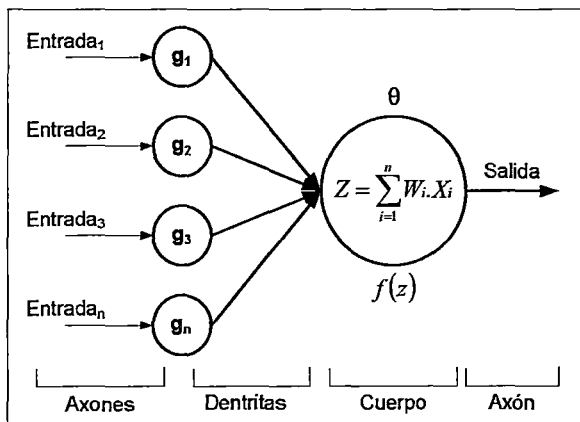


Figura 1.1. Esquema de una neurona artificial

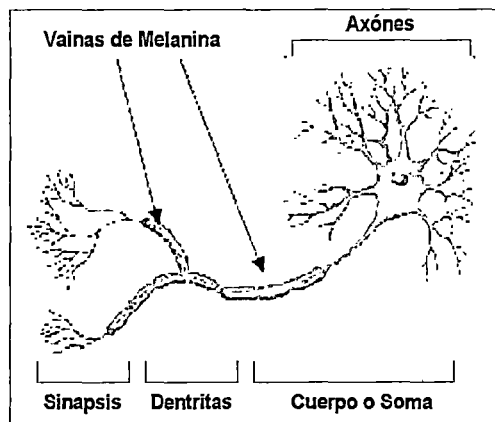


Figura 1.2. Célula neuronal del cerebro humano.

Asociada con cada unidad neuronal denominada U_i existe una función denominada de activación, $f(Net_i)$, que transforma la entrada neta de la neurona en una señal de salida $y_i(t) = f(Net_i(t))$. La salida está dada por una función continua cualquiera definida dentro de un intervalo. Toda función con límites inferiores y superiores y que posea un incremento monótonico será una función de activación satisfactoria. Las funciones de activación típicas son:

- **Función Escalón:** la salida, que en este caso es binaria, solo se activa cuando la entrada neta es mayor a cierto valor umbral predefinido:

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

Como el valor *Umbral* es definido por el usuario, se suele tomar el valor medio de la máxima suma de las entradas.

- **Función Sigmoidal (o logística):** Un caso particular sería la función lineal mixta $f(x) = x$. La función de activación sigmoidal es la más utilizada en la actualidad:

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

$f(x)$ es una función continua, derivable y acotada dentro del intervalo $[0, 1]$

- **Función Gaussiana:** la campana de Gauss permite de manera muy simple centrar el intervalo (en ancho y altura) en el que se desean obtener las salidas determinadas para cada una de las neuronas.

$$f(x) = \frac{1}{\sigma_i \sqrt{2\pi}} e^{-1/2 \frac{(x - \mu_i)^2}{\sigma_i^2}}$$

Donde μ_i es la media de la clase i y σ_i es la varianza de la clase i .

- **Función de base radial.** Las más habituales son funciones gaussianas no monótonas del tipo.

$$gB(x) = \exp\left(-\frac{x^2}{2\sigma^2}\right)$$

Donde σ define la anchura. La función alcanza su valor máximo cuando la entrada es cero.

2.2.4.3. Aprendizaje de las Redes Neuronales Artificiales (RNA)

El aprendizaje de las redes neuronales artificiales se puede definir de dos maneras: como la modificación del comportamiento inducido por la interacción con el entorno y como resultado de las experiencias conducentes al establecimiento de nuevos modelos de respuesta a estímulos externos (Zurada, 1992).

En el campo de las redes neuronales, el aprendizaje es el proceso por el cual una señal modifica los pesos de la red en respuesta a la información de entrada (Krishnamoorthy, 1996). Existen dos criterios para clasificar el tipo de aprendizaje: el primero respecto a la supervisión, que se divide en:

- **Supervisado:** el entrenamiento es controlado por un agente externo, denominado maestro o supervisor, que determina la respuesta que debería generar la red y en caso de no coincidir la respuesta real con la deseada, el supervisor procede a modificar el peso W_i de las conexiones. Algunas formas de llevarlo a cabo son:
 - i. **Aprendizaje por corrección de errores:** Ajusta los pesos de las conexiones en función del error cometido en la salida. Un ejemplo es la regla de aprendizaje del Perceptrón que desarrolló Rosenblatt en 1958. El algoritmo planteado consideraba únicamente los errores individuales teniendo en cuenta los errores individuales y no el error global cometido durante el proceso completo de aprendizaje de la red, por lo tanto este algoritmo fue mejorado por Widrow y Hoff (1960) (Widrow et al., 1960) y fue denominado regla delta o regla del mínimo error cuadrado (LMSE).

$$Error_{global} = \frac{1}{2P} \sum_{k=1}^P \sum_{j=1}^N (y_j^{(k)} - d_j^{(k)})^2$$

Siendo:

N : Número de neuronas de salida.

P : Número de informaciones que debe aprender la red.

Otro algoritmo de aprendizaje por corrección de errores es el Least Mean Square Error (LMS) y se trata de una generalización de la regla delta para redes forward con n capas ocultas Rumelhart et al., (1986).

- ii. **Aprendizaje por refuerzo:** Durante el entrenamiento no se indica la salida que se desea que proporcione la red ante una determinada entrada. Entonces, la función del supervisor es, la de indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada; en función de ello se ajustan los pesos basándose en un mecanismo de probabilidades. Una implementación del algoritmo por refuerzo lo constituye el denominado Linear Reward-Penalty o LR-P de Narendra y Thathacher en 1974 (Narendra et al., 1974).
- iii. **Aprendizaje estocástico:** Consiste en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidades. Una vez realizados los cambios se determina la energía de la red, la cual es una función denominada de Lyapunov Hopfield, (1982). Si la energía es menor después del cambio: el comportamiento de la red se acerca al deseado y se acepta el cambio. Sino, solo se acepta el cambio según una distribución de probabilidades. Una red que utiliza este tipo de aprendizaje es la Boltzman Machina ideada por Hinton, Ackley y Sejnowsky en 1984, Ackley et al., (1985).
- **No Supervisado:** En este caso no existe un agente externo que controle el proceso de aprendizaje de la red, por lo que se lo denomina autosupervisado. La red no recibe información externa que le aclare si la salida generada fue correcta o no. Existen varias formas

de interpretar la salida de estas redes, las cuales dependen de su estructura, organización y algoritmo de aprendizaje que la generó, pero se podría decir que la salida representa el grado de familiaridad entre la información que se le proporciona a la entrada y la información entregada hasta entonces. Algunas maneras de llevar a cabo este tipo de aprendizaje son:

- i. **Aprendizaje Hebbiano:** Hebb en 1949 postuló: “Cuando un axón de una celda A está suficientemente cerca como para conseguir excitar una celda B y repetida o persistentemente toma parte en su activación, entonces algún proceso de crecimiento o cambio metabólico tiene lugar en una o ambas celdas, de tal forma que la eficiencia de A, cuando la celda a activar es B, aumenta”. Hebb entiende por celda a un conjunto de neuronas fuertemente conectadas a través de una estructura compleja (Hebb, 1949).

Se trata de una regla de aprendizaje no supervisado, pues la modificación de los pesos se realiza en función de las salidas de las neuronas obtenidas tras la presentación de cierto estímulo, sin tener en cuenta si se deseaba obtener o no esos estados de activación.

- ii. **Aprendizaje Competitivo y Cooperativo:** En este caso las neuronas compiten (y cooperan) unas con otras con el fin de llevar a cabo una tarea dada. Cuando se presenta cierta información de entrada, sólo una de las neuronas de salida de la red, o una por determinado grupo de neuronas, se activa alcanzando su valor de respuesta máximo. Por lo tanto, las neuronas compiten por su activación, quedando una por grupo, como neurona vencedora (Winner Take All Unit) y anulando el resto de las neuronas, que son forzadas al valor de respuesta mínimo. Los mapas autoorganizados o SOM (Self-Organizing Map), también llamados

redes de Kohonen, utilizan este tipo de aprendizaje (Kohonen, 2001).

2.2.4.4. Topología de las Redes Neuronales

La topología es la disposición de las neuronas que forman la red, las cuales forman capas o agrupaciones de neuronas que están alejadas en mayor o menor medida de la entrada y la salida de la red. En este sentido, los parámetros fundamentales de red son:

- El número de capas.
- El número de neuronas por capa.
- El grado de conectividad.
- El tipo de conexiones entre neuronas.

Se puede presentar también, una clasificación según el número de capas. En cada caso se describirán brevemente las distintas implementaciones que existen para cada una de ellas:

- **Redes Monocapa:** En las redes monocapa, las neuronas que componen la única capa que existe, deben cumplir las tres funciones básicas de la red: de entrada de datos, de procesamiento de datos y de salida de información. Pueden existir conexiones autoconcurrentes o no. Algunas de las implementaciones más conocidas son:
 -
- **Redes Multicapa:** Disponen de conjuntos de neuronas agrupadas en varios niveles (donde $n \geq 2$). Ahora las conexiones de las neuronas pueden estar solas en una capa, en varias o en todas; por lo tanto vale la pena aclarar los dos tipos básicos de redes multicapa:
 - ✓ **Feedforward:** Donde todas las señales neuronales se propagan hacia delante a través de las capas de la red. Normalmente las conexiones recurrentes no son útiles en aplicaciones de reconocimiento o clasificación de patrones.

- ✓ **Feedforward/feedback:** En este tipo de redes circula información tanto hacia delante como hacia atrás durante el funcionamiento de la red. Algunas redes neuronales tienen un funcionamiento denominado resonancia, donde la información de las n capas interactúa entre sí hasta que alcanza un estado estable.

A continuación se analizarán en particular las dos redes que serán utilizadas en el desarrollo de la investigación, que son las redes PERCEPTRON Multicapa y las redes de función de base radial.

2.2.4.5. PERCEPTRON Multicapa (MLP)

En 1986 Rumelhart, Hinton y Williams, desarrollaron un método de aprendizaje automático que logró que una red neuronal basada en el PERCEPTRON (Rosenblatt, 1958) aprendiera la asociación que existe entre los patrones de entrada y las clases correspondientes de salidas.

El Aprendizaje Automático o “Machine Learning” podría definirse como un conjunto de programas computacionales que mejoran con la experiencia. Estos sistemas deben ser capaces de adquirir conocimientos de alto nivel para la resolución de problemas mediante ejemplos provistos por un instructor o supervisor debiendo generar representaciones internas de los conceptos.

Para lograrlo, se modificó la red del PERCEPTON de Rosenblatt (1958) agregándole capas ocultas, con conexión hacia delante y sin conexiones recurrentes. No fue suficiente con introducir algunas modificaciones topológicas a la red, sino que se requerían modificaciones en el algoritmo de aprendizaje; por lo tanto fue desarrollado el método de aprendizaje no supervisado denominado también Backpropagation, basado en la regla Delta Generalizada (Rumelhart et al., 1986), logrando así, una ampliación del rango de aplicación de las redes neuronales.

El funcionamiento general de una red neuronal artificial del tipo PERCEPTRON, como el de otras redes neuronales, puede dividirse en dos partes: la etapa de entrenamiento y la etapa de puesta en marcha. La primera consiste en el aprendizaje de un conjunto predefinido de observaciones de entrada-salida dados como ejemplo (utilizando n atributos de entrada y un único atributo o clase, de salida), empleando un ciclo propagación-adaptación de dos fases (García Martínez et al., 2003; Rumelhart, 1986):

- **Primera Fase:** Se aplican los atributos de entrada en la capa de entrada de datos de la red. Los valores generados por las neuronas de entrada se propagan desde la capa de entrada hacia las capas superiores hasta generar una salida, en la capa de salida de la red. Para realizar el entrenamiento, se compara el resultado obtenido en cada neurona de salida con el valor deseado para cada neurona en particular y se obtiene un error para cada una de las unidades de salida.
- **Segunda Fase:** Los errores de las unidades de salida se transmiten hacia atrás, pasando por todas las neuronas de las capas intermedias que contribuyan directamente a la salida, recibiendo el porcentaje de error aproximado a la participación de las neuronas intermedias en la salida original. Este proceso se repite capa por capa hasta llegar a la capa de entrada y hasta que cada neurona haya recibido un error que describa su aporte al error total.

Es por esto que este algoritmo se denomina también de retro-propagación o propagación hacia atrás, donde los errores se calculan con respecto a los aportes de las neuronas desde la capa de salida hasta la capa de entrada y es con respecto al valor del error recibido que se reajustan los pesos de las conexiones entre cada par de neuronas en la red, de manera de que el error total cometido para ese patrón disminuya.

En la fase de funcionamiento normal, los pesos no se modifican y por lo tanto, dados los atributos en las neuronas de entrada, se obtienen las distintas activaciones de las neuronas de salida como cualquiera de las redes neuronales que no cumplen con la característica "Winner Takes All" (del inglés. el ganador toma todo) de esta sección.

Dado que la fase de funcionamiento es similar a las redes estudiadas se debe realizar un análisis más profundo en el método de aprendizaje. El método de *Back-propagation* utiliza una función o superficie de error asociada a la red, buscando el estado de mínimo error estable a través del camino descendente de la superficie de error (Rumelhart, 1986). Es por esto que de debe realizar la retroalimentación para realizar las modificaciones en los pesos en un valor proporcional al gradiente decreciente de dicha función de error.

2.2.4.5.1. Funcionamiento de las redes PERCEPTRON Multicapa (MLP)

Dada una neurona U_i y su salida Y_i , el cambio que se produce en el peso de la conexión que une la salida de dicha neurona con la unidad $U_j(w_{ij})$ para un patrón de aprendizaje p es:

$$P_K = [a_1^{(k)}, a_2^{(k)}, a_3^{(k)}, \dots, a_n^{(k)}, s_n^{(k)}]$$

$$\Delta w_{ij}(t+1) = \alpha \cdot \delta_{ij} \cdot Y_{pi}$$

Donde el subíndice p se refiere al patrón de aprendizaje concreto y α es la constante o tasa de aprendizaje. La regla delta generalizada difiere con la regla delta en el valor concreto de δ_{pj} . En las redes con capas ocultas como esta se desconocen las salidas internas deseadas de las capas para poder calcular los pesos en función del error cometido. Sin embargo, inicialmente podemos conocer la salida deseada de las neuronas de salida. Para la unidad U_j de salida, se define:

$$\delta_{pj} = (d_{pj} - Y_{pj}) \cdot f'(Net_j)$$

Donde d_{pj} es la salida deseada de la red para la neurona j y el patrón p y Net_j es la entrada neta de la neurona j . Si U_j pertenece a una de las capas ocultas o entradas, se tiene:

$$\delta_{pj} = \left(\sum_{k=1}^N \delta_{pk} \cdot w_{kj} \right) \cdot f'(Net_j)$$

Donde el rango de k cubre todas las neuronas a las que está conectada la salida de U_j y el error que se produce en una neurona oculta es la suma de todos los errores cometidos por las neuronas a las que está conectada su salida, multiplicados por el peso de la conexión correspondiente.

2.2.4.5.2. Aprendizaje de las redes PERCEPTRON Multicapa

La regla o algoritmo de Back-propagation, consiste en dos procesos, uno hacia adelante (forward pass) y uno hacia atrás (backward pass). Haykin, S. (1999)

En el primero, se coloca a la entrada de la red una señal de entrenamiento, la cual atraviesa la misma generando una salida que es comparada con la salida deseada, produciéndose una señal de error por cada neurona de la capa de salida.

En el segundo, dicha señal de error es propagada desde la salida hacia atrás, donde se realiza la actualización y modificación de los pesos sinápticos en función de la razón de aprendizaje, el gradiente local y la entrada de la neurona específica.

Este proceso termina según un criterio de parada, el cual permite un error mínimo en la red.

2.2.4.5.3. Campos de Aplicación

Los campos de aplicación de las redes neuronales artificiales son variados y están planteados en distintos trabajos de investigación, como el desarrollado Cinca y Gallizo Larraz. Una clasificación de los tipos de aplicaciones de las redes puede ser:

- **Para optimización:** Determinan la solución de un problema tal que sea aceptable. Generalmente, se aplican redes retroalimentadas como la de Hopfield (1982), Fausett (1994) y se utilizan en campos como el manejo de niveles de tesorería, existencias, producción, etc.
- **Para reconocimiento:** En este caso se entrena a las redes para lograr detectar patrones específicos, como pueden ser sonidos, números, letras, lenguaje humano escrito en general y representar el resultado en código ASCII, UNICODE o cualquier otro.
- **Para generalización:** Se entrena la red con casos reales y después se la utiliza para evaluar casos futuros. Especialmente se la utiliza en la clasificación (*clustering*) o predicción de un elemento nuevo dentro de grupos existentes.

2.2.4.6. Red de Funciones de Base Radial (FBR)

Este modelo de red introducido por Broomhead y Lowe (1988) tiene una arquitectura muy similar a un PERCEPTRÓN Multicapa (MLP) por ser unidireccional, pero su forma de aprendizaje es diferente. Permite modelar con relativa facilidad sistemas no lineales arbitrarios con un tiempo de entrenamiento mucho menor que el del backpropagation clásico.

2.2.4.6.1. Función de Base Radial (FBR)

Una Función de Base Radial (FBR), ϕ_i , es aquella cuya salida es simétrica alrededor de un centro asociado \bar{c}_i y se puede expresar como:

$$\phi_i(\bar{X}) = \phi(\|\bar{X} - \bar{c}_i\| - d_i)$$

En forma general $\bar{c}_i \in R^n$, $\|\bar{x} - \bar{c}_i\|$ representa la distancia r del punto evaluado al centro llamado, y $d_i \in R$ es un factor de escala para r y como $\|\cdot\|$ se suele escoger la norma vectorial Euclídea en R^n .

En la Tabla 2.1 se muestran las distintas posibilidades para determinar la forma de una FBR.

NOMBRE	EXPRESION
Función Gaussiana	$e^{\frac{-r^2}{2d^2}}$
Función Spline	$r^2 \log(r)$
Función Multicuadrática	$(r^2 + d^2)^{\frac{1}{2}}$
Función Multicuadrática Inversa	$(r^2 + d^2)^{-\frac{1}{2}}$
Función Softmax	$\frac{\exp(x_i)}{\sum_{j=1}^n \exp(x_j)}$

Tabla 2.1 Formas posibles de ϕ

En el estudio de Rojas, I., Valenzuela, O., and Prieto, A., (1997) sobre las distintas formas que puede adoptar una FBR a la hora de formar parte de una Red de Funciones de Base Radial, en el cual se concluye que una FBR con forma gaussiana es una de las mejores elecciones. La figura 2.1

muestra la forma de las funciones base gaussiana y multicuadrática, con los parámetros $c = 0$ y $\alpha = 1$




Figura N° 2.1 Funciones de Base Radial gaussiana y multicuadrática $c = 0$ y $\alpha = 1$

2.2.4.6.2. Arquitectura de la Red de Función de Base Radial

Una Red de Funciones de Base Radial (FBR) es una red hacia adelante (feedforward network) que contiene tres capas (Ver figura N° 2.2):

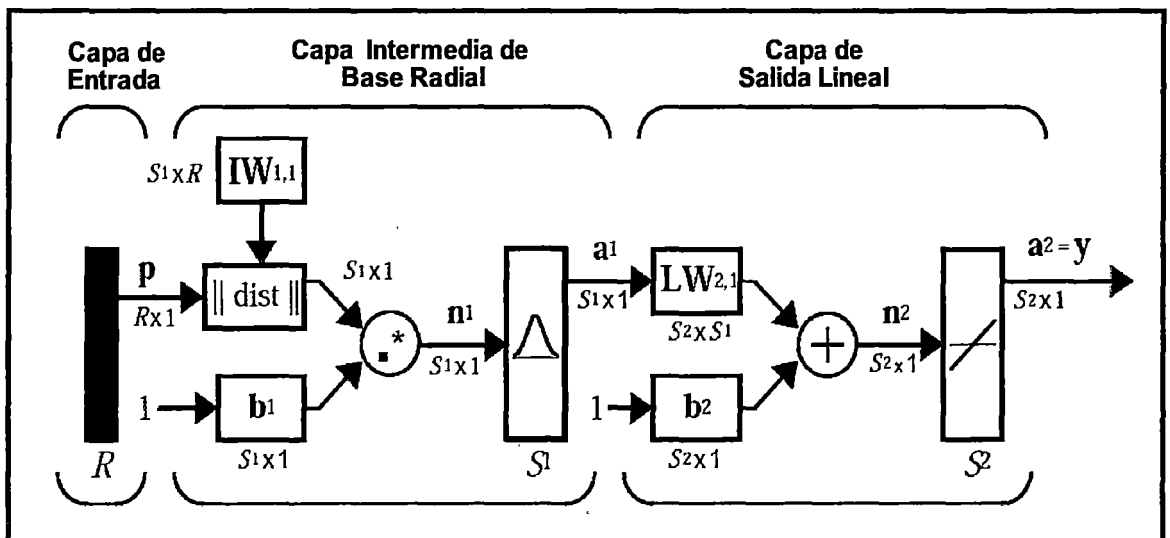


Figura N° 2.2 Arquitectura de una red de base radial

- Capa de entrada: Con neuronas de entrada que envían la información del exterior hacia la capa intermedia.

- Capa oculta: Completamente interconectada entre todos sus nodos con la capa de entrada. Cada neurona de la capa oculta se caracteriza por que su salida viene dada por una FBR comúnmente una función gaussiana. La activación de estas funciones es proporcional a la cercanía, medida por la norma euclídea, entre el patrón de entrada y centro c_i correspondiente. Si el patrón de entrada está cerca del centro de una FBR, la salida de esta se acercará a 1, en caso contrario se acercará a 0.
- Capa de salida: Está completamente interconectada a la capa oculta activada a través de una función lineal continua.

Para describir el modelo, las neuronas de la capa de entrada se denominan x_i , las de salida de la capa oculta serán y_j , y z_k de la capa de salida. Cada neurona j de la capa oculta almacena un vector c_{ji} , el centroide; cada una de estas neuronas calculan la distancia euclídea r_j que separa el vector de entradas x_i de su centroide.

$$r^2 = \|x - c_j\|^2 = \sum_1 (x_i - c_{ji})^2$$

Para la salida de la neurona de la capa oculta y_j se calcula a partir de una función de activación en este caso una función de base radial gaussiana

$\phi(r) = e^{-r^2/2d^2}$ obteniendo:

$$y_j = e^{-r_j^2/2d_j^2} = e^{-\sum_i (x_i - c_{ji})^2 / 2d_j^2}$$

El factor de escala o anchura d es el término empleado para identificar a la amplitud de la campana de gauss originada por la función radial. Es decir, la desviación estándar de la función radial (ver figura 2.3). Algunos autores (Lowe, D., 1989) consideran a este ancho como un valor constante para cada una de las funciones radiales consideradas en la capa oculta y de este

modo, así contribuiría a simplificar los pasos de construcción del modelo de entrenamiento de la red.

Entonces, si el vector de entradas x_i coincide con el centroide c_j de la neurona j ésta responde con máxima salida, la unidad. Es decir, cuando el vector de entradas se sitúa en una región próxima al centroide de una neurona, ésta se activa, indicando que reconoce el patrón de entrada; si el patrón de entrada es muy diferente del centroide, la respuesta tiende a cero. Se ha considerado funciones radiales simétricas, en algunos casos se elige una d diferente para cada dirección, d_j adquiriendo formas elipsoidales.

Las neuronas de la capa salida calculan su respuesta con las salidas de las neuronas de la capa oculta y son:

$$z_k = \sum_j w_{kj} y_j + \theta_k = \sum_j w_{kj} \phi(r_j) + \theta_k$$

Siendo w_{kj} el peso que conecta la neurona oculta j con la salida k , y θ_k un parámetro adicional de la neurona k , que por similitud con el PERCEPTRON se denominan umbrales (bías).




Figura 2.3 Respuesta localizada de las neuronas ocultas en el BF (nodos gaussianos) en el espacio de trabajo.

2.2.4.6.3. Algoritmo de Aprendizaje en la FBR

En el proceso de aprendizaje como primer paso es cómo elegir el número de nodos radiales (ocultos). Cada nodo radial cubre una parte del espacio de entrada (ver figura 2.3), de modo que habrá que elegir el número de nodos adecuados que cubra suficientemente dicho espacio para una determinada aplicación.

Surge un problema al tratar con espacios de entrada de muchas variables, pues el número de nodos crece exponencialmente. En Martín del Brío (2002) propone que se debe llegar a un acuerdo entre el número de nodos radiales seleccionados, el error que se alcanza en el ajuste de los patrones de aprendizaje, y la capacidad de generalización. Todo ello apoyado por el método de ensayo y error u otra técnica similar como el Algoritmo autoorganizado jerárquico que consiste en comenzar con un determinado número reducido de nodos gaussianos y si algún patrón de entrada no activa en suficiente medida ninguna de estas neuronas ocultas procedemos a introducir una nueva que sea sensible a la presencia de una nueva clase de patrones.

Seguidamente se procede al aprendizaje por etapas aplicando a la arquitectura de la red el método de descenso por el gradiente.

2.2.4.6.4. Aprendizaje en dos fases

Este modelo de aprendizaje o entrenamiento es el más utilizado. En primer lugar se realiza el entrenamiento de las neuronas ocultas gaussianas y se finaliza con el entrenamiento de las neuronas de salida.

2.2.4.6.5. Entrenamiento de los neuronas ocultas gaussianas

Primeramente, se deben fijar los valores para los centroides y radios, luego determinar los valores para los pesos. Para el entrenamiento de los centros se pueden utilizar métodos de agrupamiento o clustering no supervisados como el conocido algoritmo de las K-medias (Mood, 1989).

En el algoritmo de las k -medias, k hace referencia al número de grupos o clusters que se desea encontrar y sigue el siguiente proceso:

1. Se eligen los valores de los k centroides c_j de partida. Usualmente se toman los primeros k patrones de aprendizaje cuya elección inicial no es relevante para el resultado final.
2. En cada iteración t se reparten los patrones de aprendizaje x entre las k neuronas. Cada patrón se asigna a la neurona de cuyo centroide dista menos.
3. Se calculan los nuevos centroides de cada neurona como promedio de los patrones de aprendizaje asignados en el paso (2) y se tiene:

$$c_{jt} = \frac{1}{N_j} \sum x, x \in \text{neurona } j$$

4. Si los valores de los centroides no han variado respecto de la iteración anterior, el algoritmo ya ha convergido de lo contrario volver al paso (2).

La utilización de k -medias permite generar un conjunto de puntos del espacio de entrada representativos de cada una de las regiones en las que está definida la función a estimar o los patrones a clasificar.

Tras el correspondiente establecimiento de radios y pesos, la FBR proporcionará soluciones aceptables al menos en aquellas regiones en las que existan bastantes patrones de entrenamiento y en los que la función a estimar se comporte de manera similar a la FBR utilizada. No obstante, al ser un mecanismo no supervisado, no tiene en cuenta que valores de entrada cercanos puedan ofrecer salidas muy distintas entre sí, lo cual limita su utilización.

El inconveniente del k -medias es que trata de seleccionar puntos del espacio de entrada representativos nuevamente del conjunto total de los patrones disponibles, pero esta vez teniendo en cuenta las distintas regiones del

espacio de salida. Además, el algoritmo no garantiza que el conjunto de centros sea el óptimo para ser usado dentro de una RNFBP, tanto en el número de ellos como en las posiciones que ocupan.

Por su parte, el proceso de entrenamiento de los radios es también una tarea crítica, pues tanto puede llevar al sobre-entrenamiento de la red (radios demasiado pequeños) como a hacerla excesivamente suave (radios demasiado grandes). A pesar de ello, la forma en que generalmente se establecen estos radios es mediante heurísticas, el cual se basa en calcular de forma aproximada el radio de influencia en el espacio de entradas de cada neurona en relación a las demás, para lo cual se procede de la siguiente forma: para calcular el d_j de la neurona j seleccionaremos los centroides de las N neuronas que estén más próximas al del nodo j , y a continuación calcularemos el promedio de las distancias cuadráticas (Warwick, 1995), es decir:

$$d_j^2 = \frac{1}{N} \sum_{N=1}^1 \|c_c - c_j\|^2 = \frac{1}{N} \sum_{l=1}^N \sum_k (c_{lk} - c_{ik})^2$$

En el caso de redes totalmente simétricas, el único radio existente puede ser establecido como un valor proporcional a la media de las k menores distancias calculadas entre todos los distintos pares de centros diferentes que se puedan establecer. Para el caso de redes parcialmente simétricas o asimétricas, se pueden establecer el radio de cada FBR usando un valor proporcional a la media de las distancias de los k centros más cercanos a su centro. Si se ha realizado la elección mediante agrupamiento, también puede utilizarse la media de las distancias de los patrones que pertenecen al grupo con respecto al centro elegido como representante. En cualquier caso, tanto el valor k como el coeficiente de proporcionalidad aplicado han de ser establecidos manualmente.

Sea cual sea el método utilizado para determinar los centros y radios de la red, el siguiente paso consiste en modificar los pesos de los enlaces, intentando minimizar el error cometido al aproximar los patrones de entrenamiento.

2.2.4.6.6. Entrenamiento de las neuronas de salida.

Los valores de las neuronas de la capa oculta de las funciones son numéricos con los cuales se procede a calcular los pesos w_{kj} y umbrales θ_k aplicando el algoritmo LMS a la expresión de salida de la capa final.

$$z_k = \sum_j w_{kj} \phi(r_j) + \theta_k$$

Se transforma en:

$$w_{kj}(t+1) = w_{kj}(t) + \varepsilon(t_k - z_k) \phi(r_j)$$

Donde t_k son los valores objetivo o target. Los umbrales se actualizan siguiendo el mismo esquema, considerando que se trata de pesos con entradas de valor -1.

Al tener dos tipos de aprendizaje: no supervisado por la capa oculta y supervisada por la capa de salida se puede decir que este modelo de red es híbrida.

CAPITULO III

METODOLOGIA DE LA INVESTIGACION

3.1. TIPO DE INVESTIGACION

Los datos considerados son los ratios financieros obtenidos de la empresas en el periodo 1993 - 2003, debido a que se quiere mostrar la aplicación de las redes neuronales artificiales a la identificación de la situación financiera, se pasará entonces por la etapa correlacional, donde se explicará la relación de las diversas variables involucradas en la investigación para finalmente emitir conclusiones con respecto al mejor modelo para la identificación de la solvencia o insolvencia empresarial dentro y fuera de muestra respectivamente, así como la complejidad, ventajas y limitaciones de la metodología propuesta.

3.2. DISEÑO DE LA INVESTIGACION

La presente investigación tiene como propósito ver como influye los modelos de redes neuronales artificiales (PERCEPTRON Multicapa y Función de base Radial) en la identificación de la situación financiera, dado que no es posible realizar la manipulación de los datos de manera arbitraria en cuanto a sus valores, puesto que éstos son fijos y obtenidos de los estados financieros históricos de las empresas solvente e insolventes, por lo que este estudio no es experimental.

3.3. POBLACIÓN Y MUESTRA

3.3.1. Población o Universo

En la presente investigación, para determinar el universo de estudio se ha seguido un procedimiento de exclusión, según los objetivos, alcances del trabajo y la disponibilidad de información.

Así, de las 5.788 empresas con problemas económico - financieros comprendidas en el Sistema de Reestructuración Patrimonial durante el período 1993 - 2001, se tuvo en cuenta sólo a 4.524 empresas (78,2%) enmarcadas dentro del Procedimiento de Insolvencia; es decir, quedaron excluidas las empresas que se acogieron al Procedimiento Simplificado, Concurso Preventivo y Procedimiento Transitorio, debido a que estos mecanismos recién fueron implementados entre 1997 - 2000.

Además, estos últimos por ser procesos de corta duración, los expedientes no contienen la información completa requerida para la investigación. En estos casos, el objetivo de los deudores generalmente es protegerse del pago de sus obligaciones y del probable embargo de sus activos. En cambio, el Procedimiento de Insolvencia tiene la finalidad de reestructurar pasivos o en el peor de los casos, establecer un calendario de pago de deudas.

Estrategias de Selección y Muestreo

La muestra representativa se obtuvo mediante un proceso de muestreo aleatorio-probabilístico para proporciones, usando la siguiente fórmula:

$$n = \frac{(Z)^2 (p) (q) (N)}{(N-1) (E)^2 + (Z)^2 (p) (q)}$$

Donde:

$$n = \text{Tamaño de la Muestra} \quad = \quad ?$$

N = Universo o Población	=	4.524
Z = De la Normal, 5% Nivel de Significación	=	1,96
E = Precisión	=	0,05
p = Probabilidad de Éxito	=	0,5
q = Probabilidad de Fracaso	=	0,5

Reemplazando valores tenemos:

$$n = \frac{(1,96)^2 (0,5) (0,5) (4524)}{(4.524-1) (0,05)^2 + (1,96)^2 (0,5) (0,5)}$$

$$n = \frac{(3,8416) (0,5) (0,5) (4524)}{(4.523) (0,0025) + (3,8416) (0,5) (0,5)}$$

$$n = \frac{4.344,8496}{11,3075 + 0,9604}$$

$$n = \frac{4.344,8496}{12,2679}$$

$$n = \boxed{354 \text{ empresas}}$$

Sin embargo, dado los altos costos que implicaba la obtención de la información se tuvo que hacer una corrección en el tamaño de la muestra. Efectuando el mismo procedimiento de cálculo, pero con un nivel de precisión de 0,1 se obtuvo una muestra de 94 empresas con la cual se desarrolló la investigación.

CUADRO N° 04

DETERMINACIÓN DEL UNIVERSO Y LA MUESTRA POR SECTOR ECONÓMICO

SECTOR ECONÓMICO	UNIVERSO		MUESTRA	
	PI	%	E = 0,05	E = 0,1
INDUSTRIA	1.679	37,1	131	35
COMERCIO Y SERVICIOS	2.361	52,2	186	49
EXTRACCION	484	10,7	37	10
TOTAL	4.524	100,0	354	94

Nota: PI son las siglas de Procedimiento de Insolvencia.

Fuente.: Elaboración propia.

La elección de cada elemento o sujeto de la muestra (empresa insolvente) a ser estudiada, se efectuó haciendo uso de números aleatorios con lo cual se evitó los sesgos. Para aplicar este procedimiento se utilizó el Listado de Empresas en Insolvencia de los Expedientes Principales Públicos de la Comisión de Reestructuración Patrimonial del INDECOPI. En función del muestreo llevado a cabo para las empresas insolventes si incluyo las empresas solventes obtenidas de CONASEV, por cada empresa insolvente se incluyo una empresa solvente del mismo giro y periodo.

3.4. VARIABLES E INDICADORES

3.4.1. Variable Dependiente

Estado de solvencia o insolvencia empresarial.

3.4.2. Variable Independiente

Modelo de red neuronal PERCEPTRON Multicapa. Este modelo es una generalización del PERCEPTRON simple y surgió como consecuencia de las limitaciones de dicha arquitectura en lo referente al problema de la separabilidad no lineal.

Modelo de red neuronal de Base Radial. Este modelo se caracteriza por que están formadas por una única capa oculta y cada neurona de esta capa posee un carácter local, en el sentido de que cada neurona oculta de la red se activa en una región diferente del espacio de

patrones de entrada. Este carácter local viene dado por el uso de las llamadas funciones de base radial, generalmente la función gaussiana, como función de activación.

Hipótesis Específica N° 1

Variable Dependiente

Modelo de Redes Neuronales Artificial

Variable Independiente

Modelo de Análisis Discrimínate Múltiple

Hipótesis Específica N° 2

Variable Dependiente

Modelo de Redes Neuronales Artificial

Variable Independiente

Ratios financieros como variables de entrada

HIPOTESIS GENERAL	
Variable	Indicadores
V. D. Identificar el estado de solvencia e insolvencia empresarial	Eficiencia Error
V. I. Modelos de redes neuronales artificiales	Eficiencia Error Neuronas en la capa oculta
Hipótesis Específica N° 01	
V. D. Modelo de Redes Neuronales Artificial	Eficiencia Error
V. I. Modelo de Análisis Discrimínate Múltiple	Eficiencia Error
Hipótesis Específica N° 02	
V. D. Modelo de Redes Neuronales Artificial	Eficiencia Error Neuronas en la capa oculta
V. I. Ratios financieros	Indicadores financieros

3.5. TECNICAS E INSTRUMENTOS DE RECOLECCION DE DATOS

3.5.1 Técnicas de Investigación

La Estadística: Esta técnica nos permitió la recopilación, ordenación, codificación, sistematización, procesamiento y determinación de indicadores, así como la presentación de los datos secundarios convertidos en información estadística (descriptiva e inferencia) relevante para la comprobación de las hipótesis.

El Análisis Documental: Ésta fue una de las técnicas más utilizadas en la presente investigación, nos permitió recopilar, sistematizar y analizar la bibliografía especializada de textos, revistas, papers y otros.

3.5.2. Instrumentos Utilizados

En la Estadística: Los instrumentos correspondientes a esta técnica son los cuadros estadísticos simples, de doble entrada y gráficos ilustrativos de cada variable estudiada. Serán incorporados a un programa computarizado con ellos se harán el análisis y se obtendrán los resultados:

En el Análisis Documental: Los instrumentos utilizados fueron las fichas bibliográficas y hemerográficas, resúmenes de textos, recortes periodísticos, etc.

3.5.3. Procedimientos de Recolección de Datos

Datos de Carácter Financiero: Los datos correspondientes a las variables financieras consignadas en el Balance General y el Estado de Ganancias y Pérdidas, así como la información cualitativa sobre las empresas insolventes, se extrajeron utilizando el Formato de Recolección de Datos.

Los datos tuvieron que ser extraídos cuidadosa y selectivamente, debido a que éstos se encuentran dispersos en voluminosos Expedientes de Procesos Concursales, que en ciertos casos superan los diez tomos y la información obtenida de la página web de CONASEV se extrajo en una hoja de cálculo para su análisis y tratamiento.

Se señala que esta investigación debe desarrollarse dentro de las condiciones y características de una técnica de análisis documental principalmente.

3.5.4. Metodología del diseño

La metodología a seguir para el diseño del modelo de redes neuronales artificiales, se desarrollará siguiendo el siguiente esquema, el cual muestra la secuencia de pasos para la obtención del modelo.

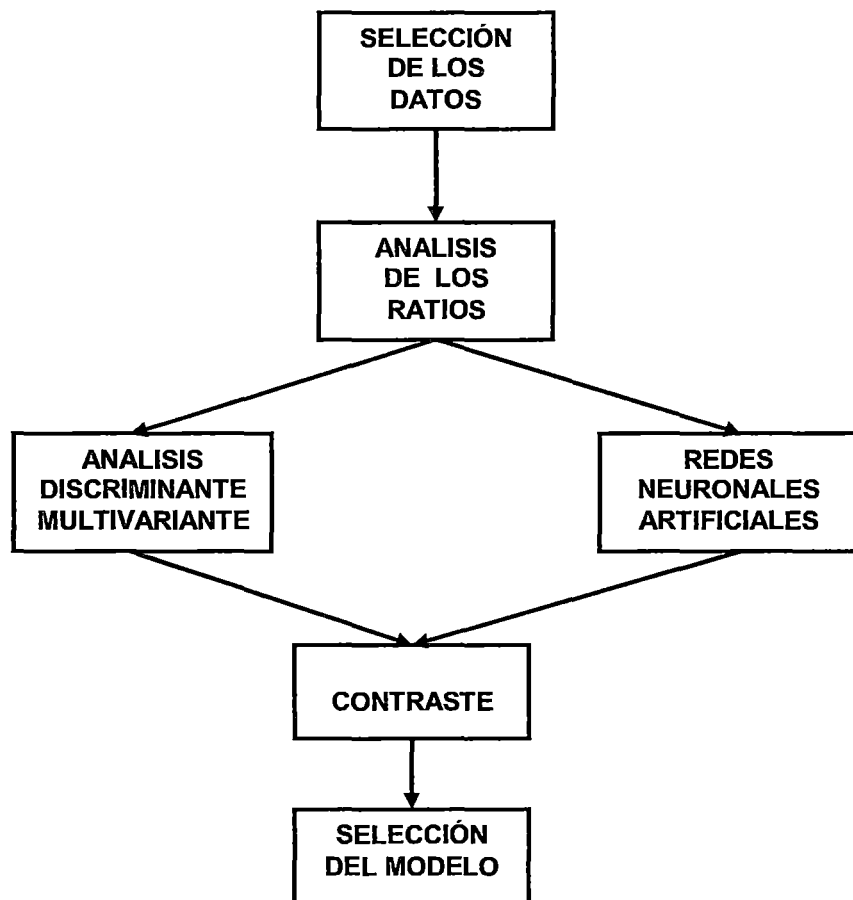


Figura 3.1. Metodología de diseño del modelo

CAPITULO IV

ANALISIS Y RESULTADOS DE INVESTIGACION

4.1. ANALISIS Y TRATAMIENTO DE LOS DATOS

4.1.1. Recolección de datos

La muestra de empresas objeto de análisis se ha restringido a empresas que están sujetas a un tipo de control, siendo el periodo de cobertura de la muestra el de 1993 al 2003. Un motivo para seleccionar este conjunto de empresas ha sido que son las únicas fuentes de información y que son datos oficiales, no se pudo tener acceso a otras fuentes como la SUNAT⁹, otorgando la información mínima requerida para llevar a cabo el análisis empírico propuesto en la presente investigación. Además, la calidad y fiabilidad de la información contenida en dichos documentos se presupone superior si se tiene en cuenta que son objeto de supervisión y regulación por parte de la CONASEV y fiscalización de los procedimientos en trámite sin que ello implique que el sistema concursal peruano por parte de INDECOPI.

Como se ha indicado en la parte metodológica, las 188 empresas insolventes y solventes a ser estudiadas en la presente investigación fueron seleccionadas en forma aleatoria, a partir de un universo que para fines del estudio se ha dividido en sector industria, extracción y comercio - servicios.

⁹ SUPERINTENDENCIA NACIONAL DE ADMINISTRACION TRIBUTARIA

Es necesario precisar que mientras el número de empresas por años se determinó al azar; advirtiéndose que en algunos períodos hay una mayor densidad de empresas, lo cual nos indica que la crisis fue más intensa en dichos años. Por otro lado, las unidades económicas sujetas a investigación son de diversos tamaños -considerando volumen de ventas y patrimonio- lo que implica que la insolvencia es un problema que afecta tanto a las pequeñas empresas, como a las grandes empresas en el Perú.

Las empresas que integran la muestra seleccionada se distribuyen en dos grupos. Uno, constituido por 94 empresas que durante el periodo objeto de análisis se han visto inmersas en algún tipo de situación concursal, que se denominará grupo de empresas insolventes, y, otro integrado por 94 empresas que no se han visto afectadas por dicho tipo de situaciones y que será denominado como grupo de empresas solventes. De las cuales el 85% se ha utilizado para establecer el modelo y el 15% para su respectiva validación como se puede apreciar en el cuadro N° 05, el mismo procedimiento se realizó con las empresas solventes. Conocidas la distribución de la muestra en esos dos grupos, por un lado, se van a analizar la naturaleza de sus diferencias, y, por otro se va a buscar un modelo o regla de comportamiento que permita la clasificación, en uno de los grupos descritos, de nuevas empresas, podría ser de alguna entidad financiera para los que a priori se desconoce su topología de pertenencia.

**CUADRO N° 05
MUESTRA POR SECTOR ECONÓMICO**

SECTOR ECONÓMICO	MUESTRA		MUESTRA	
	Insolventes y Solventes	%	Construcción del Modelo (85%)	Validación (15%)
INDUSTRIA	70	37	60	10
COMERCIO Y SERVICIOS	98	52	84	14
EXTRACCION	20	11	16	4
TOTAL	188	100,0	160	28

Fuente: Elaboración propia.

Por otro lado, en la etapa de recopilación de información se ha observado que alrededor del 50% de las empresas con personería jurídica que ingresaron al Procedimiento de Insolvencia, lo hicieron sin presentar sus Estados Financieros; esta proporción es mucho mayor en personas naturales, no obstante los requisitos que impone el INDECOPI. En el anexo N° 03 se presenta el formato de recolección de datos de acuerdo a la estructura de los estados financieros.

4.1.2. Definición y selección de los ratios financieros

Para la presente investigación se han tomado los datos fundamentales aportados por el Balance General y el Estado Ganancias y Pérdidas de las empresas solventes e insolventas obtenidas del periodo 1993 al 2003. Sin embargo, lo que caracteriza a estos Estados Financieros es la distorsión observada en las cifras de algunas cuentas del activo. En cierta forma esta situación concuerda con la descripción que hace Flint (1999), sobre las empresas quebradas al señalar que “en una quiebra lo único cierto son los pasivos, porque casi siempre las cuentas de los activos son manipuladas, infladas o maquilladas, para no mostrar un patrimonio negativo”; es decir, para no evidenciar la situación real de la empresa.

A esta aseveración Caicedo (2006) agrega que las cifras son manejadas para evadir la responsabilidad con los acreedores. Por ejemplo, hay empresas que presentan activos fijos con valores de cero, otras que registran altas cifras en gastos pagados por anticipado y por depreciación acumulada. Asimismo, se puede evidenciar que en muchos casos los Estados Financieros fueron regularizados en momentos previos al proceso de insolvencia, lo que nos indica que estas empresas también tuvieron problemas financieros por deficiencias en el manejo gerencial, ya que ante la ausencia de cifras reales y actualizadas, no pudieron detectar oportunamente las falencias financieras.

Teniendo en cuenta lo mencionado anteriormente, los indicadores financieros la base del análisis financiero tradicional, propone el uso de ratios financieros para la evaluación de la situación y evolución económica de la empresa. Sin embargo, los ratios a pesar de ser un instrumento amplio y variado, cuyo buen diseño y conocimiento permiten profundizar y resolver algunos aspectos concretos para la toma de decisiones sobre inversión, financiación, política de dividendos, y, grado de riesgo para alcanzar la estabilidad y crecimiento de la empresa en contextos globalizados, tiene una limitada capacidad para solucionar el problema sobre el cálculo real sobre: la rentabilidad, creación de valor, la solvencia, la liquidez, el endeudamiento, la productividad, aunque no se ha demostrado de manera concluyente la capacidad de los ratios por sí solos para la predicción del éxito o fracaso de una empresa, por lo que ha permitido a algunos analistas e investigadores utilizarlo en modelos de análisis financiero predictivo como materia prima de otras técnicas, en base a las características de mayor predominio.

Es necesario tener en cuenta en esta investigación, que existen dos tipos de ratios que son los teóricos y los empíricos. Los ratios teóricos están seleccionados con base a su popularidad en la literatura, en cambio los ratios empíricos son aquellos que se seleccionan de acuerdo a los resultados que han dado a través de procesos de correlación con ciertos factores.

Con respecto a su selección y reducción de los ratios en esta investigación, se ha tomado en cuenta lo que concluye (Bukovinsky, 1993) que en la utilización de numerosos ratios origina tres problemas significativos que son:

1. La falta de una teoría sólida para guiarse. Esto puede dar como resultados una colección fortuita de indicadores al ser seleccionados por su popularidad o por la intuición del investigador, esto puede llevar a incluir dos o más ratios que midan esencialmente los mismos componentes del balance general o el estado de resultados.

2. Como el conjunto de variables está compuesto por un número determinado de medidas contables. Esto es común en el caso de indicadores que están representados por ratios, pues mucho de estas pueden incluir las mismas medidas contables.
3. La inclusión de muchos indicadores. Existe la posibilidad de crear resultados de difícil interpretación que puede significar redundancia.

Teniendo en cuenta la teoría, numerosos autores citan cuatro categorías de ratios propuestas y son: la rentabilidad, la eficiencia, la solvencia y la liquidez: Sin embargo, (Rees, 1991) utiliza el término productividad para designar a los ratios como de eficiencia y además propone un factor más que denomina de apalancamiento.

El estudio de Courtis, (1978, citado en Ibarra Mares, 2009, p. 41), pues propone un marco categórico para la clasificación de los ratios financieros a través de intentar primero conformar una teoría general del análisis financiero mediante ratios. Para ello trata de explicar como deben ser utilizados los ratios con el objetivo de definir las principales características de la empresa, las cuales resume en tres variables importantes que afectan a la situación financiera y son: la rentabilidad, la solvencia y el funcionamiento de gestión.

Podemos ver que los factores que han sido más utilizados en los principales trabajos y que tienen actualmente un sólido fundamento teórico son los siguientes siete: la rentabilidad, la creación de valor, la productividad, la eficiencia, la liquidez, de gestión, la solvencia y el endeudamiento.

En el presente estudio se utilizan los índices de liquidez, solvencia, gestión y rentabilidad. Los índices o ratios financieros podemos definirlo como cocientes que miden la relación que existe entre determinadas cuentas de los Estados Financieros de las empresas, ya sea tomados individualmente o agrupados, siendo utilizados en la evaluación de las empresas y en la

gestión empresarial, por cuanto reflejan la situación financiera, la eficiencia con que han desarrollado sus operaciones y el grado de corrección con el que han sido manejados sus recursos.

- **Indices de Liquidez.**

Son aquellos que permiten medir la capacidad con la que cuentan las empresas para hacer frente a sus obligaciones de corto plazo. Otros especialistas dicen que estos indicadores muestran el nivel de solvencia financiera de corto plazo de las empresas, en función a la capacidad que tienen para pagar sus obligaciones de vencimiento a corto plazo, que se derivan del llamado “ciclo de comercialización”. En conclusión, miden cuán fácilmente las empresas pueden apoyarse sobre su tesorería.

- **Indices de Solvencia o Endeudamiento.**

Son indicadores a partir de los cuales se mide la capacidad de endeudamiento de las empresas, los mismos que explican el respaldo del que disponen las Empresas para afrontar sus obligaciones (Pasivos Corriente y no Corriente). Dicha relación calculada con respecto al Patrimonio, permite determinar la proporción en que éste se encuentra comprometido por sus deudas, brindando una idea acerca de la autonomía financiera de las empresas. Estos indicadores se presentan de dos formas: la primera, relaciona las deudas totales con el patrimonio, en tanto que la segunda, hace lo propio con las deudas a largo plazo.

Estos ratios miden la solvencia financiera de largo plazo con que cuenta la empresa, para hacer frente al pago de sus obligaciones con regularidad. Las razones de deuda a activos y deuda a capital se utilizan para la evaluación de la solvencia. A pesar de que se enfocan a la capacidad de pagarle a los acreedores a largo plazo, tanto los acreedores como los inversionistas siguen con atención la evolución

de estos ratios financieros para juzgar el grado de riesgo de insolvencia o de estabilidad en las utilidades. También se denominan ratios de apalancamiento porque muestran hasta que punto las empresas están endeudadas. En síntesis, permiten observar la capacidad de endeudamiento de la empresa, así como el financiamiento por sus deudas contraídas. Finalmente, es un indicador de estructura de capital de las empresas.

- **Indices de Gestión.**

Son aquellos que permiten evaluar los efectos de las decisiones y las políticas seguidas por la empresa en la utilización de sus fondos, en lo referente a cobros, ventas al crédito, inventarios y ventas totales. Es decir, miden la efectividad con que se vienen utilizando los recursos de la empresa.

Permiten evaluar el nivel de actividad y la eficacia con la cual se están utilizando los recursos disponibles, a partir del cálculo del número de rotaciones de determinadas partidas del Balance General durante el año, de la estructura de las inversiones y del peso relativo de los diversos componentes del gasto, sobre los ingresos que genera la empresa a través de las ventas. Es importante mencionar que una gestión más eficaz, reflejo del resultado de las políticas de inversión, ventas y cobranzas aplicadas, incidirá en la obtención de mejores niveles de liquidez y rentabilidad para las empresas.

- **Indices de Rentabilidad.**

Los índices de rentabilidad permiten evaluar el resultado de gestión empresarial, se obtienen como un cociente producto de relacionar utilidades netas con el patrimonio, así como con los rubros de capital social, capital adicional y participación patrimonial del trabajo. Adicionalmente, surgen de relacionar la utilidad bruta (ventas netas menos costo de ventas) y las ventas netas.

Con la selección de estos indicadores como variables explicativas para la identificación de la insolvencia y solvencia empresarial de acuerdo de la revisión de varias investigaciones relevantes y de la literatura de análisis financiero de modo de incluir todos aquellos ratios más frecuentes utilizados. De esta forma fue elaborada la lista de 14 ratios que hicieron parte del análisis en el cuadro N° 06, agrupados, bajo un criterio simplificador, en cuatro grupos principales: Liquidez, Solvencia o Endeudamiento, Gestión y Rentabilidad. Y su definición se puede apreciar en el cuadro N° 07.

CUADRO N° 06
INDICES FINANCIEROS

Ratios Financiero	Abreviatura	Variable	Índice
Indice Corriente o Liquidez General	LG	Raz. Corr.	Indices de Liquidez
Prueba Acida	PA	Prub. Aci.	
Endeudamiento Total.	ET	Raz. End.	Indices de Solvencia o Endeudamiento
Solvencia Patrimonial.	SP	Raz. Pat.	
Indice de Capitalización	IC	Ind. Cap.	
Cobertura del Activo Fijo	CAF	Raz. Cob AF	
Plazo Promedio de Cobranza	PPC	PPC	Indices de Gestión
Plazo de Inmovilización de Existencias	PIE	PIE	
Rotación del Activo Fijo	RAF	RAF	
Rotación del Activo Total	RAT	RAT	
Costo de Ventas a Ventas	CVV	CVV	
Rentabilidad Sobre el Capital Propio (ROE).	RCP	ROE	Indices de Rentabilidad
Rentabilidad Sobre la Inversión (ROA)	RI	ROA	
Rentabilidad Sobre las Ventas.	RV	RSV	

Fuente.: Elaboración propia.

CUADRO N° 07
DESCRIPCION E INTERPRETACION DE LOS INDICES FINANCIEROS UTILIZADOS EN EL ESTUDIO

RATIOS FINANCIEROS	FÓRMULA	APLICACIÓN	INTERPRETACIÓN DEL INDICADOR
I. LIQUIDEZ. 1. Índice Corriente o Liquidez General.	$L.G. = \frac{\text{ACTIVO CORRIENTE}}{\text{PASIVO CORRIENTE}}$	Permite determinar la capacidad de pago en el corto plazo de la empresa. Mide la capacidad máxima de endeudamiento en el corto plazo.	Indica el grado de cobertura que tienen los activos de mayor liquidez (disponibles, exigibles y realizables) sobre las obligaciones de menor vencimiento o mayor exigibilidad. Cuanto mayor sea el ratio, mayor será la capacidad de la empresa para satisfacer las deudas que vencen a corto plazo. Se considera aceptable cuando la relación es de 2:1.
2. Prueba Ácida.	$P.A. = \frac{\text{ACT. CTE.} - \text{EXIST.} - \text{GAST. PAG. x ANTICIPADO}}{\text{PASIVO CORRIENTE}}$	Mide en forma más precisa la liquidez de la empresa, al considerar sólo los activos más líquidos, prescindiendo de aquellos activos menos realizables, y los gastos pagados por anticipado por ser desembolsos ya realizados.	Es una medida más exigente sobre la capacidad de corto plazo que posee la empresa para cumplir con sus obligaciones corrientes, pues sólo considera sus activos corrientes disponibles y exigibles más no los realizables. Se considera aceptable cuando la relación es de 1:1.
II. SOLVENCIA O ENDEUDAMIENTO. 1. Endeudamiento Total.	$E.T. = \frac{\text{PASIVO TOTAL}}{\text{ACTIVO TOTAL}}$	Mide la proporción del total de activos aportados por los acreedores de la empresa; es decir, el grado de dependencia del capital ajeno. Permite apreciar la solvencia financiera en la capacidad de endeudamiento de la empresa, y el retorno de la inversión.	Es un indicador de riesgo financiero (posibilidad de que la empresa no cumpla con sus obligaciones financieras) de la empresa, y depende de la política financiera que aplica ésta. Un mayor apalancamiento financiero implica un mayor financiamiento a través de deuda, y por lo tanto, un mayor riesgo financiero y menor solvencia para la empresa. Lo óptimo es que el ratio no sea mayor a 0.3 (30%).
2. Solvencia Patrimonial.	$S.P. = \frac{\text{PATRIMONIO NETO}}{\text{PASIVO TOTAL}}$	Permite establecer la relación entre el capital propio y el capital ajeno, así como el nivel de endeudamiento de la empresa. Mide el respaldo que brinda el patrimonio de la empresa a los capitales de terceros.	Es un indicador que evidencia el nivel de compromiso de los recursos propios de la empresa con los recursos de terceros. Si el ratio es mayor a uno, la empresa tendrá menos comprometidos sus recursos propios y por lo tanto será más solvente. Se considera satisfactorio cuando es mayor a 1.0 (100%).
3. Índice de Capitalización.	$I.C. = \frac{\text{DEUDA A LARGO PLAZO}}{\text{DEUDA A LARGO PLAZO} + \text{PATRIMONIO}}$	Mide la participación del capital ajeno en el financiamiento de largo plazo de la empresa (capital permanente de la empresa). Permite establecer la relación entre los fondos a largo plazo que suministran los acreedores y los que aportan los dueños de la empresa, así como el impacto del endeudamiento a largo plazo en la solvencia de la misma.	Es un indicador de estructura de capital. Cuanto más elevada sea la participación del capital ajeno en el capital total, más peligrosos serán los impactos negativos del mercado o de las pérdidas de explotación; en consecuencia, será menor su resistencia a las crisis. Un menor índice de capitalización ofrece mayor seguridad económica y aumenta la solvencia para la solicitud de créditos. De acuerdo a los fundamentos teóricos y la evidencia empírica, lo óptimo es que la proporción de capital ajeno no supere de 0.3 (30%), en la estructura de capital.
4. Cobertura del Activo Fijo.	$C.A.F. = \frac{\text{DEUDA A LARGO PLAZO} + \text{PATRIMONIO NETO}}{\text{ACTIVO FIJO NETO}}$	Permite medir la participación de los capitales propio y ajeno, de larga permanencia, en el financiamiento de las inversiones efectuadas por la empresa.	Cuanto menos sea este ratio a la unidad, una mayor proporción de los activos circulantes de la empresa, estará financiada con capitales permanentes o de largo plazo, contando con una mayor solvencia financiera. Lo ideal es que el ratio sea mayor a 1.0, pues indica mayor solvencia financiera.
III. GESTION. 1. Plazo Promedio de Cobranza.	$P.P.C. = \frac{\text{CUENTAS x COBRAR COMERCIALES} * 360 \text{ DIAS}}{\text{VENTAS NETAS}}$	Sirve para medir la velocidad o plazo de retorno de los créditos. Es el periodo probable de convertibilidad de las ventas realizadas, en efectivo.	Determinan el número de días que en promedio transcurren entre el momento en que se realiza la venta y el momento en que se hace efectivo el cobro. Lo óptimo es que el periodo promedio de cobros no supere los 30 días.

2. Plazo de Inmovilización de Existencias.	P.I.E. = $\frac{\text{EXISTENCIAS} * 360 \text{ DÍAS}}{\text{COSTO DE VENTAS}}$	Permite establecer el número de días en promedio que toma vender o consumir todas las existencias, o las veces que han sido remplazadas durante un periodo determinado, con el objeto de mantener stocks adecuados.	Expresan el número de días que en promedio, los productos terminados se mantienen en el almacén. Depende del sector. También se puede considerar como el número de días que transcurre entre la adquisición de una materia prima y la venta del producto terminado. Tiempo en que el stock tarda en convertirse en efectivo. Lo ideal es tener un período promedio de rotación de existencias de 30 días. Depende de la actividad.
3. Rotación de Activo Fijo.	R.A.F. = $\frac{\text{VENTAS NETAS}}{\text{ACTIVO FIJO NETO}}$	Permite medir la productividad de la planta o fábrica en proporción a la inversión efectuada en bienes permanentes o inmovilizados.	Este ratio también es conocido como Rotación de Inmuebles, Maquinaria y Equipo. Se interpreta como la medición de la eficiencia relativa con la cual la empresa ha utilizado los bienes de capital para generar ingresos a través de las ventas. Lo ideal es que este indicador sea de 20 veces por año.
4. Rotación del Activo Total.	R.A.T. = $\frac{\text{VENTAS NETAS}}{\text{ACTIVO TOTAL}}$	Sirve para medir la eficiencia en el uso de los activos de la empresa, con relación a los ingresos generados por la actividad del negocio.	Expresa la eficiencia en el empleo de todos los activos de la empresa para la generación de ingresos. Una rotación elevada indica una gran actividad de la empresa. Lo ideal es tener un ratio elevado porque indica un mejor uso del Activo Total en la generación de ventas. Se considera que el óptimo es de 5.
5. Costo de Ventas a Ventas.	C.V.V. = $\frac{\text{COSTO DE VENTAS}}{\text{VENTAS}}$	Este ratio permite indicar la proporción en que los ingresos generados por la empresa mediante ventas, han sido absorbidos por los costos aplicados en la producción de los productos terminados.	Refleja la proporción de las ventas que son absorbidas por su costo. Cuanto menor sea este indicador, la empresa viene administrando eficientemente sus costos, por lo tanto, la Utilidad Bruta será mayor. Lo ideal es que el ratio no supere de 0.7 (70%) como proporción de costos respecto a las ventas.
IV. RENTABILIDAD. 1. Rentabilidad Sobre el Capital Propio (ROE).	R.C.P. = $\frac{\text{UTILIDAD NETA}}{\text{PATRIMONIO NETO}} \times 100$	Sirve para medir el rendimiento de los recursos propios mediante la utilidad que han generado las inversiones de la empresa.	Expresa el rendimiento neto obtenido en función de los recursos propios de la empresa. En la medida que este índice sea positivo la empresa habrá generado una mayor utilidad neta por unidad monetaria invertida. Lo ideal es tener un Índice de Rentabilidad para el Capital Propio de 0.2 (20%) anual.
2. Rentabilidad Sobre la Inversión (ROA).	R.I. = $\frac{\text{UTILIDAD NETA}}{\text{ACTIVO TOTAL}} \times 100$	Permite medir el rendimiento de la inversión efectuada por la empresa, como consecuencia del uso de los recursos propios y ajenos.	Es un indicador del éxito global de una inversión comparando el retorno de tal inversión con la inversión que inicialmente se hizo. Mide el rendimiento de la inversión realizada, como consecuencia del uso de recursos propios y ajenos. Lo ideal es tener el mayor Índice de Rentabilidad promedio del sector económico. Se considera un óptimo de 0.3 (30%) anual.
3. Rentabilidad Sobre las Ventas.	R.V. = $\frac{\text{UTILIDAD NETA}}{\text{VENTAS NETAS}} \times 100$	Sirve para determinar la ganancia con respecto a las ventas generadas. Permite establecer el rendimiento de las ventas en comparación con los gastos operativos, financieros y otros, los que no corresponden a operaciones normales de la empresa.	Expresa la rentabilidad neta generada por la empresa, después de intereses e impuestos por unidad monetaria vendida. A medida que sea mayor el índice, la empresa habrá generado mayores utilidades, lo cual mide la eficiencia relativa de la misma. Es ideal tener un Índice de Rentabilidad Sobre las Ventas de 0.1 (10%).

Fuente: Elaboración Propia

4.1.3. Información estadística de las variables

En los anexos N° 01 y N° 02 se muestra los ratios de las 188 empresas teniendo en cuenta las empresas solventes y las empresa insolventes. Cabe indicar, para fines de la investigación se clasificaron en tres sectores económicos industria, comercio y servicio, extracción, tomando como referencia la Clasificación Industrial Internacional Uniforme (CIIU), no se ha tomado en cuenta las entidades financieras debido a su estructura de los estados financieros.

4.2. ANALISIS ESTADISTICO

El análisis estadístico consta dos fases que son:

Etapas Experimentales:
Etapa Experimental 1: Análisis discriminante con dos grupos y una variable clasificadora, empleando los 14 ratios como variable independiente.

Etapa Experimental 2: Análisis discriminante stepwise con dos grupos y una variable clasificadora.

4.2.1. Análisis Discriminante Múltiple

Las limitaciones de los ratios dentro de un análisis tradicional han llevado a no pocas investigaciones sobre el tema a la necesidad de utilizar otras técnicas modernas de análisis financiero más globales y de mayor alcance basadas en la estadística, que se inserten en un marco de modelos decisorios, como es el caso de los Modelos Univariados y Multivariados. La investigación empírica realizada con ambos modelos dentro del análisis de la solvencia o insolvencia se ha orientado principalmente hacia un caso particular: la predicción de quiebras. Los modelos predictivos, que incluyen un conjunto de métodos estadísticos avanzados, se enfocan hacia el contenido de la información contable expresada en las razones o ratios.

Los modelos univariados utilizan una sola variable independiente mientras los multivariados, que son los más desarrollados, hacen uso de una

combinación de variables independientes para analizar dinámicamente las actividades financieras y económicas de la empresa con el fin de reducir variables y predecir problemas de solvencia e insolvencia, caso en el cual se han utilizado los ratios insertados en este modelo y denomina análisis discriminante.

Nuestro trabajo trata de diferenciar entre dos grupos de empresas (solventes e insolventes), se aplica el análisis discriminante, es una técnica estadística que permite clasificar una nueva observación en uno de los dos grupos definidos a priori. La clasificación se obtiene por una función discriminante que es una combinación lineal de las variables. En cuanto a las variables independientes (ratios financieros) que permiten explicar el comportamiento de la variable respuesta, este método impone la condición de que sean cuantitativas o métricas. En el caso que nos ocupa se ha seleccionado el análisis discriminante a ratios o razones financieras, pues es el método que mejor nos permite perfeccionar la selección de la base de datos traducida a razones, y nos permita hacer una comparación con las Redes Neuronales Artificiales.

4.2.2.1. Análisis discriminante con dos grupos y una variable clasificadora

Para la presente investigación los resultados obtenidos a través del Análisis Discriminante haciendo uso del programa PASW Statistics Base empleando los 14 ratios financieros seleccionados de la muestra que esta conformada de 188 empresas, 160 empresas nos ayudara a construir el modelo a través de este análisis y 28 empresa servirán para la validación, y que a continuación empezamos a detallar, el cuadro N° 08 muestra la media y la desviación típica para cada grupo (insolvente y solvente) y para el total de la muestra. En esta tabla se de reparar en aquellas variables independientes con mayores diferencias en las medias entre los dos grupos de referencia. Estas en principio tienen potencial de discriminación. Evidentemente, no nos podemos quedar en este análisis superficial. El resto de tablas nos irán

confirmando o descartando esta primera impresión. Con el ANOVA mostrada en el anexo N° 04 nos permite identificar que media grupales son significativamente diferentes de otras, como también se toma en cuenta el estadístico de la razón F y teniendo en consideración su valor crítico a un nivel de significancia del 0,05.

Así mismos, procede acometer una prueba de igualdad de medias. El cuadro N° 09 muestra la λ del Wilks (cociente entre la suma de cuadrados intragrupos y la suma de cuadrados total en un análisis de varianza simple para cada una de las v_i por separado asumiendo que la variable independiente métrica es X). Evidentemente, cuando la variabilidad total se puede atribuir a la diferencia entre las medias de los distintos grupos, λ tendrá valores cercanos a 0. Valores de λ próximos a la unidad sugieren la no existencia de diferencia entre las medias de las variables estudiadas entre las empresas solventes y las insolventes. F es el mismo estadístico que se calcula en el análisis de medias simple. Las dos columnas del cuadro N° 09 hacen referencia a los grados de libertad y la última al grado de significancia.

Para nuestra investigación, la prueba de igualdad (F) nos revela que existen diferencias de medias entre los dos grupos, en las variables solvencia patrimonial (Raz Pat), endeudamiento total (Raz End), prueba ácida (Prub Aci), índice corriente (Raz Corr) y rotación del activo total (RAT), excepto en las otras razones. Para estas el λ del Wilks asociadas muy próximas a la unidad, mientras que para las otras variables, sus lambdas asociadas tienen valores significativamente más reducidos.

**CUADRO N° 08
ESTADÍSTICOS DE GRUPO**

CONDICION		Media	Desviación típica
Insolvente	Raz Pat	-0,2745	0,47162
	Ind Cap	-1,2108	11,31307
	Raz Cob AF	-2,4495	94,75067
	PPC	107,7918	257,83426
	PIE	143,1513	684,46610
	RAF	26,3729	53,34056
	RAT	2,2545	3,84198
	CV/V	0,7968	1,23125
	ROE	-1,3584	16,08362
	ROA	-0,7299	2,44508
	RSV	-1,8051	10,62668
	Raz Corr	0,7364	0,84870
	Prub Aci	0,4461	0,54669
	Raz End	3,1860	4,44236
Solvente	Raz Pat	4,5540	11,62616
	Ind Cap	0,2044	0,20419
	Raz Cob AF	45,1225	211,70426
	PPC	102,3060	240,48141
	PIE	161,4211	231,16456
	RAF	3,8640	11,35733
	RAT	0,5619	0,40784
	CV/V	0,6921	0,30028
	ROE	-2,2830	25,80426
	ROA	1,0131	7,63117
	RSV	0,5516	88,49627
	Raz Corr	2,0900	1,81087
	Prub Aci	1,3433	1,60876
	Raz End	0,3981	0,22678

CUADRO N° 09
PRUEBAS DE IGUALDAD DE LAS MEDIAS DE LOS GRUPOS

Ratios	Lambda de Wilks	F	gl1	gl2	Sig.
Raz Pat	0,920	13,776	1	158	0,000
Ind Cap	0,992	1,251	1	158	0,265
Raz Cob AF	0,979	3,365	1	158	0,068
PPC	1,000	0,019	1	158	0,889
PIE	1,000	0,051	1	158	0,821
RAF	0,921	13,628	1	158	0,000
RAT	0,911	15,354	1	158	0,000
CVV	0,997	0,545	1	158	0,461
ROE	1,000	0,074	1	158	0,786
ROA	0,977	3,785	1	158	0,053
RSV	1,000	0,056	1	158	0,813
Raz Corr	0,812	36,649	1	158	0,000
Prub Aci	0,876	22,304	1	158	0,000
Raz End	0,834	31,426	1	158	0,000

Fuente: Elaboración Propia con el programa PASW Statistics Base

CUADRO N° 10
LOGARITMO DE LOS DETERMINANTES

CONDICION	Rango	Logaritmo del determinante
Insolvente	14	54,943
Solvente	14	41,435
Intra-grupos combinada	14	67,254

Los rangos y logaritmos naturales de los determinantes impresos son los de las matrices de covarianzas de los grupos

Fuente: Elaboración Propia con el programa PASW Statistics Base.

CUADRO N° 11
RESULTADOS DE LA PRUEBA

M de Box		3.012,331
F	Aprox.	26,029
	gl1	105
	gl2	77.772,741
	Sig.	0,000

Contrasta la hipótesis nula de que las matrices de covarianzas poblacionales son iguales.

Fuente: Elaboración Propia con el programa PASW Statistics Base

A continuación se precede analizar la prueba M de Box (cuadros N° 10 y 11). Esencialmente, se pretende contrastar en que medida las matrices de varianza-covarianza para cada uno de los dos grupos de referencia (Solventes – Insolventes) proceden o no de la misma población, es decir, si difieren o no significativamente. Asumiendo que la hipótesis nula de esta prueba es que la matrices citadas no presentas diferencias significativas entre los dos grupos, el hecho de que el estadístico F sea igual a 26,029 con un nivel de significancia del 0,000 (cuadro N° 11) nos permite rechazar la mencionada hipótesis nula y afirmar la existencia de diferencias entre los grupos, la principal información sobre las funciones discriminantes figura en los siguientes cuadros:

En primer lugar, el cuadro N° 12 realiza el cálculo del autovalor como cociente entre la suma de cuadrados entregrupos y la suma de cuadrados intragrupos. Parece claro que la calidad de la función discriminante va a estar vinculada a la presencia de valores altos para este cociente. También se calcula el porcentaje de varianza y el acumulado vinculado a la función discriminante que es del 100 por ciento al tratarse de una sola función. Finalmente, el cuadro N° 12 muestra una medida de asociación entre las puntuaciones discriminantes y los grupos a través del cálculo de la correlación canónica.

**CUADRO N° 12
AUTOVALORES**

Función	Autovalor	% de varianza	% acumulado	Correlación canónica
1	0,620 ^a	100,0	100,0	0,619

a. Se han empleado las 1 primeras funciones discriminantes canónicas en el análisis.
Fuente: Elaboración Propia con el programa PASW Statistics Base

La λ Wilks (cuadro N° 13) expresa cuál es la proporción de la varianza total de las puntuaciones discriminantes que no está explicada por las diferencias entre grupos (SC intragrupos/SC total). Se propone en la misma tabla un contraste χ^2 asociado a la λ del Wilks donde la hipótesis nula hace referencia a la no existencia de diferencias en las puntuaciones otorgadas a las diferentes variables independientes entre las dos categorías de referencia. Para la presente investigación, la $p = 0,000$ aconseja que se rechace la hipótesis nula y, en consecuencia, se preconiza la diferencia entre grupos.

**CUADRO N° 13
LAMBDA DE WILKS**

Contraste de las funciones	Lambda de Wilks	Chi-cuadrado	gl	Sig.
1	0,617	72,807	14	0,000

Fuente: Elaboración Propia con el programa PASW Statistics Base

En concreto, el cuadro N° 14 nos muestra los componentes básicos de la función discriminante, la cual será una combinación lineal de las variables independientes que nos van permitir el cálculo de la puntuación discriminante a partir de la siguiente expresión:

$$D = - 0,007 - 0,022 \text{ Raz Pat} + 0,146 \text{ Raz End} + 0,603 \text{ Prub Aci} - 0,829 \text{ Raz Corr} + 0,003 \text{ Ind Cap} - 0,002 \text{ Raz Cob AF} + 0,001 \text{ PPC} + 0,000 \text{ PIE} + 0,008 \text{ RAF} + 0,102 \text{ RAT} + 0,120 \text{ CV/V} + 0,003 \text{ ROE} - 0,019 \text{ ROA} + 0,007 \text{ RSV}$$

CUADRO N° 14
COEFICIENTES DE LAS FUNCIONES
CANÓNICAS DISCRIMINANTES

Ratios	Función
	1
Raz Pat	-0,022
Ind Cap	0,003
Raz Cob AF	-0,002
PPC	0,001
PIE	0,000
RAF	0,008
RAT	0,102
CV/V	0,120
ROE	0,003
ROA	-0,019
RSV	0,007
Raz Corr	-0,829
Prub Aci	0,603
Raz End	0,146
(Constante)	-0,007

Coeficientes no tipificados
Fuente: Elaboración Propia con el programa PASW
Statitics Base

Los coeficientes estandarizados (cuadro N° 15) se obtiene a partir de las puntuaciones directas anteriores. Tiene la misma interpretación que sus homónimos de la regresión lineal clásica. Evitan el efecto escala y son medidas, de la dirección de la relación (positiva o negativa) y de su intensidad (valor absoluto del coeficiente).

El cuadro N° 16 nos expresa la correlación existente entre los valores de la función discriminante y los de las variables independientes. Es, por tanto, una forma alternativa de expresar en que medida cada variable contribuye a la función discriminante. En la investigación, la que guarda mayor relación lineal es índice corriente (Raz Corr = 0,612) y la que menos plazo promedio de cobranza (PPC =0,014). El signo nos indica el sentido de la relación.

CUADRO N° 15
COEFICIENTES ESTANDARIZADOS DE LAS
FUNCIONES DISCRIMINANTES
CANÓNICAS

	Función
	1
Raz Pat	-0,181
Ind Cap	0,022
Raz Cob AF	-0,282
PPC	0,207
PIE	0,097
RAF	0,320
RAT	0,278
CV/V	0,107
ROE	0,064
ROA	-0,107
RSV	0,453
Raz Corr	-1,173
Prub Aci	0,725
Raz End	0,460

Fuente: Elaboración Propia con el programa PASW Statistics Base

A partir de la función discriminante y de las puntuaciones aportadas por ella para cada dato de la muestra procede establecer la clasificación. Es decir, precisamos, en este punto, una metodología que agrupe a los datos en cada uno de los dos grupos de referencia establecidos a priori. Teniendo en cuenta el programa utilizado PASW Statistics Base realiza esta clasificación utilizando el análisis bayesiano. Este combina el uso de la probabilidad previa que aporta información sobre el grado de probabilidad de una puntuación discriminante cualquiera para los integrantes de un grupo u otro. El teorema de Bayes permite calcular la probabilidad a posteriori o probabilidad de que un dato de nuestra muestra, dada una puntuación discriminante determinada, pertenece a un grupo u otro. Ver anexo N° 05.

En el cuadro N° 17, denominado matriz de confusión, es el resumen de clasificación: Figuran el número de entidades que han sido clasificados de forma correcta o incorrecta sobre el total de la muestra. En nuestro caso se puede observar que de las 80 empresas insolventes tan solo 13 se asignaron al grupo de empresas solventes (un error, en consecuencia, del 16,30%). De las 80 empresas solventes, solo seis se clasificaron erróneamente como insolventes. En total este modelo discriminante ha clasificado correctamente 88,1% de los casos.

**CUADRO N° 16
MATRIZ DE ESTRUCTURA**

Ratios	Función
	1
Raz Corr	-0,612
Raz End	0,567
Prub Aci	-0,477
RAT	0,396
Raz Pat	-0,375
RAF	0,373
ROA	-0,197
Raz Cob AF	-0,185
Ind Cap	-0,113
CV/V	0,075
ROE	0,027
RSV	-0,024
PIE	-0,023
PPC	0,014
Correlaciones intra-grupo combinadas entre las variables discriminantes y las funciones discriminantes canónicas tipificadas Variables ordenadas por el tamaño de la correlación con la función.	

Fuente: Elaboración Propia con el programa PASW Statistics Base

CUADRO N° 17
RESULTADOS DE LA CLASIFICACIÓN^A

CONDICION			Grupo de pertenencia pronosticado		Total
			Insolvente	Solvente	
Original	Recuento	Insolvente	67	13	80
		Solvente	6	74	80
	%	Insolvente	83,8	16,3	100,0
		Solvente	7,5	92,5	100,0

^a Clasificados correctamente el 88.1% de los casos agrupados originales.
Fuente: Elaboración Propia con el programa PASW S Statitics Base

A continuación, se presenta los histogramas relativos a las puntuaciones discriminantes relativas a cada uno de los grupos por separado. Las puntuaciones discriminantes figuran en el eje de las abscisas mientras que las frecuencias figuran en las ordenadas. Los histogramas aportan información sobre el número de entidades (N), las medias de cada uno de los grupos o centroides (para el grupo de las insolventes, +0,782; para las empresas de solventes -0,782 y las desviaciones típicas (1,154 y 0,818, respectivamente). La información sobre los centroides aparece reflejada igualmente en el cuadro N° 18.

CUADRO N° 18
FUNCIONES EN LOS CENTROIDES DE LOS GRUPOS


CONDICION	Función
	1
Insolvente	0,782
Solvente	-0,782

Funciones discriminantes canónicas no tipificadas
evaluadas en las medias de los grupos

Fuente: Elaboración Propia con el programa PASW
Statitics Base

Función discriminante canónica 1

CONDICION = Insolvente



Función discriminante canónica 1

CONDICION = Solvente




Figura 4.1: Funciones Discriminantes Canónicas

Nuestro interés hasta esta parte del estudio se centro en combinar linealmente las variables predictoras para predecir el grupo, ahora reside en clasificar individuos en grupos, particularmente en nuestro caso entidades (empresas) de las cuales desconocemos su grupo de pertenencia, pero de las que tenemos medidas las variables predictoras, utilizaremos las funciones de clasificación lineal que son también combinaciones lineales de las variables predictoras, remplazando a las función discriminante lineales. En el cuadro N° 19 recoge la salida del programa PASW Statistics Base de los coeficientes de la función de clasificación lineal, para la caso de la investigación presente, identificación de la solvencia e insolvencia empresarial.

CUADRO N° 19
COEFICIENTES DE LA FUNCIÓN DE
CLASIFICACIÓN

	CONDICION	
	Insolvente	Solvente
Raz Pat	-0,056	-0,021
Ind Cap	0,016	0,011
Raz Cob AF	-0,002	0,001
PPC	0,003	0,002
PIE	0,001	0,000
RAF	0,012	-0,001
RAT	0,257	0,098
CV/V	1,173	0,986
ROE	-0,004	-0,009
ROA	-0,049	-0,019
RSV	0,007	-0,004
Raz Corr	1,043	2,340
Prub Aci	-0,316	-1,260
Raz End	0,414	0,185
(Constante)	-2,817	-2,806

Funciones discriminantes lineales de Fisher

Fuente: Elaboración Propia con el programa PASW Statistics Base

Una vez que se tiene los coeficientes lo relevante es clasificar en los grupos a las entidades (empresas) cuya pertenencia al grupo es conocida y evaluar el ajuste de la predicción del grupo, y obtener la validación con las 28 empresas. Los resultados se presentan en el anexo N° 06.

4.2.2.2. Análisis discriminante Stepwise con dos grupos y una variable clasificadora

Con el modelo discriminante que acabamos de comentar va a operar con todas los ratios sugeridos. Ahora bien, es posible que queramos conocer cuales son los ratios (variables entrada) con mayor poder discriminante y, apelando al principio de parsimonia, introducir en nuestro modelo el menor número de variables explicativas (ratios). Este procedimiento coincide con el algoritmo utilizado en la regresión múltiple. Es decir, establecemos un método dinámico articulado en una serie de pasos de inclusión de variables de acuerdo con su capacidad discriminante. A medida que avanzamos en los pasos este algoritmo comprobaba que todas las variables incluidas en las fases anteriores cumplen los requisitos de permanencia y, al tiempo, se introducen nuevas variables que satisfacen el criterio de inclusión. Este procedimiento llegará a su fin cuando no quede en el exterior del modelo ninguna variable que cumpla con el criterio de entrada y, simultáneamente, todas las que figuran en el modelo observen los criterios de permanencia.

La idea del Análisis discriminante "Stepwise" hacia delante, es construir un modelo paso a paso, revisando todas las variables y evaluando cuál puede contribuir más a la discriminación entre grupos. Esta variable podrá ser incluida en el modelo.

Para la presente investigación, el análisis discriminante realiza en tres pasos y, en consecuencia, formula una función discriminante con tres variables razón corriente (Raz Corr), razón de endeudamiento (Raz End) y rotación del activo fijo (RAF). Dado con anterioridad (véase cuadro N° 13) se indico como

criterio de selección el determinado por λ del Wilks, las variables deberán ir entrando y saliendo del modelo en función del menor valor con que este estadístico se vaya presentando. El número de pasos posibles es el doble del número de variables independientes (2 x 14 variables independientes = 28 pasos). De acuerdo con las especificaciones introducidas, la F mínimo para entrar es 3,84 y la F máxima para salir 2,71. Ver cuadro N° 20.

A continuación, las salidas utilizando el programa PASW Statistics Base aportan información relativa a las variables incluidas en cada uno de los pasos del análisis (en nuestro caso, se produce tres pasos ver cuadro N° 21) y las que igualmente, por pasos quedan fuera, (véase cuadro N° 22). En esta última salida, se aporta información previa al análisis relativa a la tolerancia (ésta es el complemento a la unidad del coeficiente de correlación múltiple entre una variable y toda las demás cuando la primera actúa como dependiente y el resto como independiente en un modelo de regresión múltiple), a la tolerancia mínima, a la F para entrar en el modelo y al estadístico de Wilks. Evidentemente, este paso previo hace que la tolerancia de todas las variables sea igual a la unidad ya que ninguna, por el momento, se ha introducido en el modelo. Entrará en el paso siguiente aquella variable con menor λ de Wilks (índice corriente). A partir de este momento el proceso continúa evaluando el cumplimiento de los criterios de entrada (F mayor y por encima del mínimo para entrar y λ del Wilks con valor más pequeño) y de permanencia. Tras la entrada de índice corriente (Raz Corr), posteriormente ingresa endeudamiento total (Raz End) y finalmente rotación del activo total (RAT), por lo anteriormente indicado, finaliza el proceso ya que la F para entrar es 3,84 y ninguna de las variables lo alcanza.

CUADRO N° 20
VARIABLES INTRODUCIDAS/EXCLUIDAS^{a,b,c,d}

Paso	Introducidas	LAMBDA DE WILKS							
		Estadístico	gl1	gl2	gl3	F exacta			
						Estadístico	gl1	Gl2	Sig.
1	Raz Corr	0,812	1	1	158,000	36,649	1	158,000	0,000
2	Raz End	0,729	2	1	158,000	29,193	2	157,000	0,000
3	RAF	0,671	3	1	158,000	25,500	3	156,000	0,000

En cada paso se introduce la variable que minimiza la lambda de Wilks global.

a. El número máximo de pasos es 28.

b. La F parcial mínima para entrar es 3.84.

c. La F parcial máxima para salir es 2.71

d. El nivel de F, la tolerancia o el VIN son insuficientes para continuar los cálculos.

Fuente: Elaboración Propia con el programa PASW Statistics Base

CUADRO N° 21
VARIABLES EN EL ANÁLISIS

Paso		Tolerancia	F para salir	Lambda de Wilks
1	Raz Corr	1,000	36,649	
2	Raz Corr	0,975	22,653	0,834
	Raz End	0,975	17,832	0,812
3	Raz Corr	0,972	22,619	0,768
	Raz End	0,972	17,796	0,748
	RAF	0,993	13,475	0,729

Fuente: Elaboración Propia con el programa PASW Statistics Base

CUADRO N° 22
VARIABLES NO INCLUIDAS EN EL ANÁLISIS

Paso	Tolerancia	Tolerancia mín.	F para entrar	Lambda de Wilks		
0	Raz Corr	1,000	1,000	36,649	0,812	
	Prub Aci	1,000	1,000	22,304	0,876	
	Raz End	1,000	1,000	31,426	0,834	
	Raz Pat	1,000	1,000	13,776	0,920	
	Ind Cap	1,000	1,000	1,251	0,992	
	Raz Cob AF	1,000	1,000	3,365	0,979	
	PPC	1,000	1,000	0,019	1,000	
	PIE	1,000	1,000	0,051	1,000	
	RAF	1,000	1,000	13,628	0,921	
	RAT	1,000	1,000	15,354	0,911	
	CV/V	1,000	1,000	0,545	0,997	
	ROE	1,000	1,000	0,074	1,000	
	ROA	1,000	1,000	3,785	0,977	
	RSV	1,000	1,000	0,056	1,000	
1	Prub Aci	0,149	0,149	4,019	0,791	
	Raz End	0,975	0,975	17,832	0,729	
	Raz Pat	0,661	0,661	0,044	0,811	
	Ind Cap	1,000	1,000	1,080	0,806	
	Raz Cob AF	0,984	0,984	0,918	0,807	
	PPC	0,994	0,994	0,097	0,811	
	PIE	0,999	0,999	0,004	0,812	
	RAF	0,996	0,996	13,486	0,748	
	RAT	0,999	0,999	13,718	0,746	
	CV/V	0,992	0,992	0,028	0,812	
	ROE	0,959	0,959	1,894	0,802	
	ROA	0,835	0,835	0,253	0,810	
	RSV	0,916	0,916	2,022	0,801	
	2	Prub Aci	0,148	0,146	2,304	0,718
Raz Pat		0,660	0,644	0,170	0,728	
Ind Cap		0,942	0,918	0,001	0,729	
Raz Cob AF		0,974	0,963	0,258	0,728	
PPC		0,985	0,966	0,005	0,729	
PIE		0,999	0,974	0,013	0,729	
RAF		0,993	0,972	13,475	0,671	
RAT		0,998	0,974	12,837	0,674	
CV/V		0,988	0,965	0,149	0,728	
ROE		0,957	0,933	1,249	0,723	
ROA		0,831	0,824	0,586	0,726	
RSV		0,915	0,892	1,460	0,722	
3		Prub Aci	0,148	0,146	1,952	0,663
		Raz Pat	0,657	0,640	0,026	0,671
	Ind Cap	0,934	0,914	0,100	0,671	
	Raz Cob AF	0,959	0,959	0,849	0,667	
	PPC	0,980	0,963	0,104	0,671	
	PIE	0,993	0,971	0,026	0,671	
	RAT	0,685	0,682	3,108	0,658	
	CV/V	0,988	0,962	0,222	0,670	
	ROE	0,956	0,931	0,886	0,667	
	ROA	0,831	0,821	0,589	0,668	
	RSV	0,915	0,890	1,216	0,666	

Fuente: Elaboración Propia con el programa PASW Statistics Base

La función canónica discriminante vendría definida por los coeficientes no estandarizados contenidos en el cuadro N° 23:

CUADRO N° 23
COEFICIENTES DE LAS FUNCIONES
CANÓNICAS DISCRIMINANTES

	Función
	1
Raz Corr	-0,445
Raz End	0,180
RAF	0,013
(Constante)	0,113

Coeficientes no tipificados

Fuente: Elaboración Propia con el programa PASW Statistics Base

$$D = 0,113 - 0,445 \text{ Raz Corr} + 0,180 \text{ Raz End} + 0,013 \text{ RAF}$$

Finalmente, se aporta una matriz de clasificación ver cuadro N° 24, en el que se observa que el modelo discriminante construido a partir de tres variables tiene una eficacia clasificatoria de 85.0% de los casos correctamente calculados y menor al anteriormente calculado con las 14 variables (ratios). Los resultados completos se muestran en el anexo N° 07.

CUADRO N° 24
RESULTADOS DE LA CLASIFICACIÓN^a

CONDICION		Grupo de pertenencia pronosticado		Total	
		Insolvente	Solvente		
Original	Recuento	Insolvente	62	18	80
		Solvente	6	74	80
	%	Insolvente	77,5	22,5	100,0
		Solvente	7,5	92,5	100,0

a. Clasificados correctamente el 85,0% de los casos agrupados originales.
Fuente: Elaboración Propia con el programa PASW Statistics Base

Los coeficientes de la función discriminante no están estandarizados. Debido a esto, el valor de cada coeficiente depende de las unidades de medida y no

son comparables para determinar el ratio que más influye en la discriminación. En cambio, los coeficientes estandarizados permiten determinar el ratio que más influye en la discriminación y son: índice corriente (Raz Corr), endeudamiento total (Raz End) y rotación del activo fijo (RAF) con 0,629, 0,566 y 0,493, respectivamente. El mayor valor corresponde al índice corriente, por lo tanto es el ratio de mayor poder discriminante.

De forma similar con respecto a la etapa anterior, primero se estableció la combinación lineal de las variables predictoras para predecir el grupo, luego se procede a clasificar las entidades (empresas) de las cuales se desconoce grupo de pertenencia, pero de las que tenemos medidas las variables predictoras, utilizaremos las funciones de clasificación lineal que son también combinaciones lineales de las variables predictoras, remplazando a las función discriminante lineales. En el cuadro N° 25 recoge la salida del programa PASW Statitics Base de los coeficientes de la función de clasificación lineal, para la caso de la investigación presente, identificación de la solvencia e insolvencia empresarial para esta etapa de estudio.

**CUADRO N° 25
COEFICIENTES DE LA FUNCIÓN DE
CLASIFICACIÓN**

	CONDICION	
	Insolvente	Solvente
Raz Corr	0,467	1,086
Raz End	0,369	0,118
RAF	0,018	0,001
(Constante)	-1,695	-1,853

Funciones discriminantes lineales de Fisher

Fuente: Elaboración Propia con el programa PASW
Statitics Base

Obtenidos los coeficientes lo relevante es clasificar en los grupos a las entidades (empresas) cuya pertenencia al grupo es conocida y evaluar el ajuste de la predicción del grupo, y obtener la validación con las 28 empresas. Los resultados completos se presentan en el anexo N° 08.

4.3. ANALISIS USANDO REDES NEURONALES ARTIFICIALES

Actualmente se ha constatado un gran interés en la literatura en analizar las relaciones entre las Redes Neuronales Artificiales (RNA) y los Modelos Estadísticos (ME) tradicionales, aunque la terminología es distinta a veces los concepto a los se que se apela son los mismos. Entre las propiedades de las RNA que han llamado la atención de los estadísticos destacan las relativas a su buen rendimiento ante problemas no lineales o datos con mucho ruido, y el poderse utilizar independientemente del cumplimiento de los supuestos teóricos relativos a las técnicas estadísticas y de ahí que se haya hablado de ellas como de técnicas de distribución libre o no paramétricas. Por ello las RNA han sido aplicadas a problemas de tradición estadística como predicción y clasificación a través de las llamadas redes: PERCEPTRON Multicapa y redes de función base radial, esta última son modelos híbridos estadístico/neuronales.

Nuestro objetivo es ver la capacidad de este tipo de herramientas con respecto a la identificación de la insolvencia o solvencia empresarial en contraposición a la potencia del análisis discriminante. En este sentido utilizaremos en un primer análisis el modelo de PERCEPTRON Multicapa identificado con las siglas MLP y como algoritmo el Back-propagation es el tipo de red neuronal más utilizado, por su sencillez, en diferentes campos de la investigación, para comparar los resultados con otro tipo de red neuronal supervisada, las Redes de Función de Base Radial, también conocidas con las siglas FBR. Se utiliza este tipo de red por ser prácticamente desconocido en el campo financiero y por que da un giro en el trabajo de investigación sobre la interpolación tradicional estricta en un espacio multidimensional por lo que en la actualidad son unos de los principales campos en la investigación del análisis numérico. Desde este punto de vista, el aprendizaje es equivalente a encontrar una superficie en un espacio multidimensional que dé como resultado el mejor ajuste para los datos de entrenamiento, siendo medido de una forma estadística.

El análisis haciendo uso de las redes neuronales artificiales consta de cuatro fases que son:

Etapa Experimental 1: Redes neuronales artificiales (PERCEPTRON Multicapa), utilizando 14 ratios financieros y el algoritmo de aprendizaje Back-propagation.

Etapa Experimental 2: Redes neuronales artificiales (PERCEPTRON Multicapa), utilizando 6 ratios financieros y el algoritmo de aprendizaje Back-propagation.

Etapa Experimental 3: Redes neuronales artificiales (Función de Base Radial), utilizando 14 ratios financieros.

Etapa Experimental 4: Redes neuronales artificiales (Función de Base Radial), utilizando 6 ratios financieros.

4.3.1. Redes neuronales artificiales (PERCEPTRON Multicapa), utilizando 14 ratios financieros el algoritmo de aprendizaje Back-propagation.

El modelo de red utilizado en esta etapa del experimento, es el conocido como el PERCEPTRON Multicapa se fundamenta en varios paradigmas, el principal y más utilizado es el de aprendizaje por retropropagación de error (Back-propagation). La función de transferencia o de activación utilizada fue la Sigmoide en la cual los valores de la función oscilan entre 0 y 1

Para determinar el número de neuronas en la capa oculta no existen reglas generales o teorías, aunque existen algunas recomendaciones sugeridas por varios investigadores:

- (Shih, 1994), sugiere que la topología de la red debe tener una forma piramidal, esto es, tener el mayor número de neuronas en la capa de

entrada y menos en las posteriores. Recomienda que el número de neuronas en cada capa este más o menos entre la mitad de la capa siguiente y el doble del número de la capa anterior.

- De acuerdo con (Azoff, 1994), son suficientes $2N+1$ neuronas para N entradas.
- (Baum y Haussler, 1998) sugieren que el número de neuronas sea calculado por:

$$j = \frac{me}{n+z}$$
 donde j es el número de neuronas en la capa oculta, m es el número de datos en el conjunto de entrenamiento, e es la tolerancia al error, n es el número de entradas y z es el número de salidas.

La mayoría de los investigadores no están convencidos de las recomendaciones anteriores ya que argumentan que no hay forma de determinar una buena topología de la red a partir sólo del número de entradas y salidas.

De acuerdo al Neural Network FAQ (1996), lo recomendable es empezar a probar con un número pequeño de neuronas ocultas e incrementarlo gradualmente sólo si la red neuronal parece no aprender. De esta forma, el problema del sobreajuste que puede ocurrir al existir más pesos (parámetros) que muestras de datos puede ser reducido. Este es el método que se empleará para determinar el número de neuronas en la capa oculta de la red.

Se realiza entonces un procedimiento automático de búsqueda, por medio de un "barrido" de los parámetros que determinan el comportamiento de la red, por lo que, para obtener los parámetros de la red neuronal que arroja el menor error.

Se empleará una capa de entrada con 14 neuronas en función a las variables de entrada, una sola capa oculta, ya que una capa es suficiente

por lo que en la práctica las redes neuronales con una ó dos capas ocultas son las más utilizadas y han tenido un buen desempeño. El incremento en el número de capas también incrementa el tiempo de procesamiento y el peligro de sobreajuste lo que conduce a un pobre desempeño en la predicción fuera de la muestra. El sobreajuste ocurre cuando un modelo de predicción tiene muy pocos grados de libertad. En otras palabras, se tienen relativamente pocas observaciones en relación con sus parámetros y por lo tanto es capaz de memorizar datos individuales en lugar de aprender patrones generales. En esta capa se hará variar el número de neuronas entre 14 y 30 la de salida constará de una sola capa con una sola neurona.

La etapa contó con dos tipos de datos, al igual que los modelos estadísticos: un conjunto de entrenamiento, que contiene la causa y el efecto, otro de prueba o validación. Haykin, (1994, citado por Martín del Brío y Sanz, 2002, p. 73) sostiene del todo el conjunto de entrenamiento se emplea aproximadamente un 80% de los patrones para entrenar, reservándose un 20% como conjunto de prueba.

Por lo que los ratios financieros de las empresas se dividen en dos conjuntos de datos:

- Conjunto de entrenamiento. Lo constituye el conjunto 160 empresas, 80 son solventes y 80 insolventes que nos representa el 85% del total de las empresas de la muestra. Se seleccionan de forma consecutiva y ordenada.
- Conjunto de validación o prueba. Esta formado por el conjunto de 28 empresas, 14 empresa solventes y 14 son insolventes, representado 15% del total de la empresas de la muestra, una vez seleccionados los patrones de entrenamiento. Este conjunto de datos se utiliza para evaluar la capacidad de generalización o predicción de la red.

Para el pre - procesamiento de los datos, aunque no es estrictamente necesario, puede ser recomendable realizar una transformación de los datos

(Isasi y Galván, 2003), para lo cual los datos de entrada (los ratios seleccionados), pero se tomará en cuenta primero sin normalizar y después han de ser normalizados. A estos efectos se utilizó la siguiente fórmula:

$$\tau = \frac{(x - \text{min})}{(\text{máx} - \text{min})}$$

El cuadro N° 26 se sintetiza algunos de los parámetros utilizados:

**CUADRO N° 26
PARAMETROS UTILIZADOS EN RED NEURONAL ARTIFICIAL**

OPCION	VALOR
Tasa de aprendizaje inicial	0,4
Límite inferior de la tasa de aprendizaje	0.001
Reducción de la tasa de aprendizaje, en ciclos	10
Umbral Superior	0,9
Umbral inferior	0.0
Centro de intervalo	0
Desplazamiento del intervalo	± 0,5

Fuente: Elaboración propia

Cada configuración se entrenó en la fase de aprendizaje con un máximo de 1000 ciclos.

Para esta parte de la investigación se hará uso del programa PASW Statistics Base y los módulos adicionales de para realizar esta tarea.

Luego de entrenada la red, se efectuó la validación en las 28 empresas con que se contó para esta fase; se analizaron 160 casos con diferentes configuraciones, con pesos que permanecieron constantes de los obtenidos en la fase de aprendizaje. Cada caso implicó ingresarle los 14 ratios correspondientes a una empresa y, luego del paso por la red, se obtuvo un valor de salida entre 0 y 1, utilizándose para considerarla solvente o insolvente los umbrales que se usaron en la fase de aprendizaje.

Para indicar la bondad del ajuste es a través de la suma de errores cuadráticos que la red intenta minimizar durante el proceso de entrenamiento y prueba, como el porcentaje promedio de pronósticos incorrectos debido a que la variable dependiente en nuestro caso es categórica.

Resultados con las variables de entrada (14 ratios financieros) sin normalizar

**CUADRO N° 27
INFORMACIÓN SOBRE LA RED (PERCEPTRON Multicapa - MLP 14 RATIOS)**

Capa de entrada	Variables	Indice Liquidez	Raz Corr
		Prueba Acida	Prub Aci
		Endeudamiento Total	Raz End
		Solvencia Patrimonial	Raz Pat
		Indice de Capitalización	Ind Cap
		Cobertura del Activo Fijo	Raz Cob AF
		Plazo Promedio de Cobranza	PPC
		Plazo de Inmovilización de Existencias	PIE
		Rotación del Activo Fijo	RAF
		Rotación del Activo Total	RAT
		Costo de Ventas a Ventas	CV/V
		Rentabilidad Sobre el Capital Propio	ROE
		Rentabilidad Sobre la Inversión	ROA
		Rentabilidad Sobre las Ventas	RSV
	Número de unidades ^a	14	
	Método de cambio de escala de las variables	Ninguna	
Capas ocultas	Número de capas ocultas	1	
	Número de unidades de la capa oculta 1 ^a	14 – 28 -30	
	Función de activación	Sigmoide	
Capa de salida	Variables dependientes	1	CONDICION
	Número de unidades		1
	Función de activación		Sigmoide
	Función de error		Suma de cuadrados

a. Sin incluir la unidad de sesgo
Fuente: Elaboración Propia

Se inició con 14 neuronas en la capa oculta y sucesivamente se incrementó hasta llegar a 30. En el siguiente cuadro N° 27, se muestra la información de la red, para este caso no se normalizaron los 14 ratios financieros de la empresas que conforma la muestra de entrenamiento y la muestra de prueba.

CUADRO N° 28
CLASIFICACION (RED MLP - 14 RATIOS SIN NORMALIZAR)

MUESTRA	OBSERVADO	PRONOSTICADO (14 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	51	29	63,8%
	Solvente	10	70	87,5%
	porcentaje global	38,1%	61,9%	75,6%
Prueba	Insolvente	10	4	71,4%
	Solvente	1	13	92,9%
	porcentaje global	39,3%	60,7%	82,1%
MUESTRA	OBSERVADO	PRONOSTICADO (28 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	50	30	62,5%
	Solvente	4	76	95,0%
	porcentaje global	33,8%	66,3%	78,8%
Prueba	Insolvente	10	4	71,4%
	Solvente	0	14	100,0%
	porcentaje global	35,7%	64,3%	85,7%
MUESTRA	OBSERVADO	PRONOSTICADO (30 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	50	30	62,5%
	Solvente	12	68	85,0%
	porcentaje global	38,8%	61,3%	73,8%
Prueba	Insolvente	10	4	71,4%
	solvente	1	13	92,9%
	porcentaje global	39,3%	60,7%	82,1%

Variable dependiente: CONDICION (Solvencia o Insolvencia)

Fuente: Elaboración Propia

En el cuadro N° 28, se dan a conocer los resultados más significativos obtenidos con las distintas topologías (configuraciones) en la fase de entrenamiento y de prueba, con 14 neuronas en la capa de entrada, 14, 28 y 30 neuronas en la capa oculta y una neurona en la de salida. Se puede apreciar la topología que arrojó los mejores resultados en este modelo de red neuronal PERCEPTRON Multicapa, es la siguiente topología; 14 neuronas de entrada, 14 neuronas en capa oculta y una neurona de salida.

En cuadro N° 29, mostramos las topologías obtenidas en la fase de entrenamiento y prueba, con los porcentaje de pronósticos incorrectos y la suma de errores cuadráticos, donde se complementa a la información establecida en el cuadro anterior y confirmando la mejor topología establecida es cuando en la capa oculta presenta 14 neuronas.

El resumen del modelo presenta dos puntos a considerar:

CUADRO N° 29
RESUMEN DEL MODELO
SUMA DE ERRORES CUADRATICOS Y PORCENTAJE DE PRONÓSTICOS
(RED MLP - 14 RATIOS SIN NORMALIZAR)

Numero de Neuronas		14 (Optimo)	28	30
Entrenamiento	Suma de errores cuadráticos	28,843	26,083	27,310
	Porcentaje de pronósticos incorrectos	24,4%	21,3%	26,3%
Prueba	Suma de errores cuadráticos	4,613	4,463	4,717
	Porcentaje de pronósticos incorrectos	17,9%	14,3%	17,9%

Fuente: Elaboración Propia

- El porcentaje de pronósticos incorrectos en las muestras de entrenamiento y prueba tienen la menor diferencia. (24,40% y 17,90%).
- El algoritmo de estimación se detuvo debido a que el error no disminuyó después de realizar un paso en el algoritmo.

En el cuadro N° 30 se muestra la importancia de los ratios financieros teniendo en cuenta las diferentes topologías de la red neuronal utilizada, podemos ver como influyen cada una estas variables en la determinación de la red. El análisis se basa en las muestra de entrenamiento y de prueba en forma combinada.

**CUADRO N° 30
IMPORTANCIA DE LOS RATIOS FINANCIEROS
(RED MLP - 14 RATIOS SIN NORMALIZAR)**

RATIOS	NUMEROS DE NEURONAS EN CAPA OCULTA E IMPORTANCIA DE LOS RATIOS FINANCIEROS		
	14	28	30
Raz Corr	4,5%	5,7%	7,0%
Prub Aci	6,5%	7,9%	6,8%
Raz End	15,2%	25,8%	15,7%
Raz Pat	36,4%	36,5%	37,8%
Ind Cap	33,9%	30,0%	31,9%
Raz Cob AF	70,4%	100,0%	100,0%
PPC	70,6%	50,7%	42,8%
PIE	96,9%	68,1%	59,8%
RAF	75,4%	81,6%	63,6%
RAT	12,9%	15,3%	10,5%
CV/V	7,4%	8,0%	5,8%
ROE	35,6%	41,7%	30,4%
ROA	24,1%	22,5%	27,8%
RSV	100,0%	47,3%	72,0%

Fuente: Elaboración Propia

Resultados con las variables de entrada (14 ratios financieros) normalizados

Siguiendo con el análisis, esta vez utilizando diferente topología con respecto al anterior modelo PERCEPTRON Multicapa, solo que en este caso fueron normalizados los 14 ratios financieros de las 188 empresas que conforman las respectivas muestras. En el cuadro N° 31 se muestra los resultados más significativos obtenidos:

CUADRO N° 31
CLASIFICACION (RED MLP -14 RATIOS NORMALIZADOS)

MUESTRA	OBSERVADO	PRONOSTICADO (8 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	insolvente	69	11	86,3%
	solvente	4	76	95,0%
	porcentaje global	45,6%	54,4%	90,6%
Prueba	insolvente	13	1	92,9%
	solvente	0	14	100,0%
	porcentaje global	46,4%	53,6%	96,4%
MUESTRA	OBSERVADO	PRONOSTICADO (15 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	insolvente	71	9	88,8%
	solvente	4	76	95,0%
	porcentaje global	46,9%	53,1%	91,9%
Prueba	insolvente	13	1	92,9%
	solvente	0	14	100,0%
	porcentaje global	46,4%	53,6%	96,4%
MUESTRA	OBSERVADO	PRONOSTICADO (28 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	insolvente	71	9	88,8%
	solvente	4	76	95,0%
	porcentaje global	46,9%	53,1%	91,9%
Prueba	insolvente	12	2	85,7%
	solvente	0	14	100,0%
	porcentaje global	42,9%	57,1%	92,9%

Variable dependiente: CONDICION

Fuente: Elaboración Propia

Como se puede apreciar hay una mejora, cuando se lleva a cabo la normalización, indicando que podría ser recomendable llevar a cabo dicho proceso de los datos antes de la entrada a la red.

CUADRO N° 32
RESUMEN DEL MODELO
SUMA DE ERRORES CUADRATICOS Y PORCENTAJE DE PRONÓSTICOS
(RED MLP - 14 RATIOS NORMALIZADOS)

Numero de Neuronas		8	15	28 (Optimo)
Entrenamiento	Suma de errores cuadráticos	12,473	11,953	12,330
	Porcentaje de pronósticos incorrectos	9,4%	8,1%	8,1%
Prueba	Suma de errores cuadráticos	1,963	1,551	1,609
	Porcentaje de pronósticos incorrectos	3,6%	3,6%	7,1%

Fuente: Elaboración Propia

El resumen del modelo con 28 neuronas en la capa oculta muestra un par de aspectos favorables.

- El porcentaje de pronósticos incorrectos es aproximadamente igual en las muestras de entrenamiento (8,10%) y prueba (7,10 %), lo que confirma el proceso de validación cruzada.
- El algoritmo de estimación se detuvo debido a que el error no disminuyó después de realizar un adicional en el algoritmo.

Análogamente, como en el anterior caso podemos ver en los cuadros N° 31 y N° 32, que la mejor topología del modelo de redes neuronales PERCEPTRON Multicapa, es representado con 14 neuronas de entrada, 15 neuronas en la capa oculta y una neurona de salida. Así mismo, podemos concluir, si continuamos incrementando neuronas en la capa oculta los resultado del número de aciertos no varía en forma significativa permaneciendo en promedio en 92% en la etapa de entrenamiento y no superando 93% en la validación.

En el cuadro N° 33 se muestra la importancia de las variables de entrada (ratios financieros) que es una medida que indica cuánto cambia el valor pronosticado por el modelo de la red para diferentes valores de la variable

de entrada. A modo de observación, se puede acotar que los ratios que tienen mayor poder discriminante en el análisis estadístico, tienen importancia en la determinación de la red y por consiguiente en la identificación de la solvencia o insolvencia empresarial, y son; índice de liquidez (Raz Corr) y endeudamiento total (Raz End).

CUADRO N° 33
IMPORTANCIA DE LOS RATIOS FINANCIEROS
(RED MLP - 14 RATIOS NORMALIZADOS)

RATIOS	NUMEROS DE NEURONAS EN CAPA OCULTA E IMPORTANCIA DE LOS RATIOS FINANCIEROS		
	8	15	28
Raz Corr	100,0%	100,0%	100,0%
Prub Aci	65,5%	62,6%	59,7%
Raz End	97,0%	96,3%	92,9%
Raz Pat	62,9%	59,9%	59,4%
Ind Cap	30,4%	32,1%	5,5%
Raz Cob AF	73,8%	74,1%	69,9%
PPC	37,4%	29,8%	33,0%
PIE	12,9%	18,3%	7,8%
RAF	77,0%	76,0%	76,2%
RAT	90,4%	86,7%	84,8%
CV/V	26,2%	22,4%	19,6%
ROE	5,5%	27,6%	34,5%
ROA	28,4%	16,9%	9,6%
RSV	76,9%	67,7%	42,5%

Fuente: Elaboración Propia

4.3.2. Redes neuronales artificiales (PERCEPTRON Multicapas), utilizando 6 ratios financieros y el algoritmo de aprendizaje Back-propagation.

Como se ha visto en el modelo discriminante stepwise solo considera tres ratios financieros y los resultados obtenidos no son los más adecuados, debido a la tasa del error es superior con respecto al modelo obtenido a través del análisis discriminante utilizando los 14 ratios financieros. Por lo que se ha visto por conveniente, realizar el análisis en esta etapa con 6 ratios financieros, teniéndose la inquietud de conocer cuales son los

indicadores que tienen una mayor importancia en la identificación de la insolvencia empresarial, para lo cual, se tomados en cuenta el estadístico de prueba de la razón F que se utiliza para determinar la significancia estadística con el ANOVA (Anexo II), En el caso de nuestros datos presentados en el cuadro N° 07, se obtiene una F de 13,776, 13,628, 15,354, 36,649, 22,304 y 31,426, en los indicadores; solvencia patrimonial (Raz Pat), rotación del activo fijo (RAF), rotación del activo total (RAT), índice corriente (Raz Corr), prueba ácida (Prub Acid), endeudamiento total (Raz End) respectivamente, estos valores son mayores que el valor crítico de la razón F al nivel de 0,05, que toma el valor de 3.88. Por consiguiente el valor p (sig) calculado sería $p < 0.05$. Como estamos realizando la prueba con un nivel de significancia de 0,05, afirma (Ritchey, 2006) que existe una fuerte relación y los efectos principales del grupo permite realizar predicciones precisa de la variable independiente. Por lo expuesto, en esta etapa 2, el experimento se centra en utilizar como variables de ingreso los 6 ratios financieros con mayor significancia estadística, con los mismos parámetros definidos en la etapa 1.

Resultados con las variables de entrada (6 ratios financieros) sin normalizar

Así mismo, no utilizaremos el proceso de normalización a las variables (ratios financieros) de las 160 empresas de la muestra de entrenamiento y 28 empresas de la muestra de prueba.

A continuación mostramos los resultados del modelo PERCEPTRON Multicapa generados con misma muestra de entrenamiento y evaluado con la misma muestra de prueba, utilizando en esta etapa; una capa de entrada con 6 neuronas, con neuronas cuyo número varían entre 6 y 15 en la capa oculta y una neurona en la capa de salida.

Se inició con 6 neuronas en la capa oculta y sucesivamente se incrementó hasta llegar a 15. En el siguiente cuadro N° 34, se obtiene la información de la red:

CUADRO N° 34
INFORMACIÓN SOBRE LA RED (PERCEPTRON Multicapa - MLP 6 RATIOS)

Capa de entrada	Variables	Indice Corriente	Raz Corr
		Prueba Acida	Prub Aci
		Endeudamiento Total	Raz End
		Solvencia Patrimonial	Raz Pat
		Rotación del Activo Fijo	RAF
		Rotación del Activo Total	RAT
		Número de unidades ^a	6
Capas ocultas	Número de capas ocultas	Método de cambio de escala de las Variables	Ninguna
		Número de unidades de la capa oculta 1 ^a	1
		Número de unidades de la capa oculta 1 ^a	6 – 9 -15
Capa de salida	Variables dependientes	Función de activación	Sigmoide
		Número de unidades	CONDICION
		Número de unidades	1
		Función de activación	Sigmoide
		Función de error	Suma de cuadrados

a. Sin incluir la unidad de sesgo

Fuente: Elaboración Propia

En el cuadro N° 35 y N° 36, se muestra los resultados más significativos de cada modelo generados con la misma muestra de entrenamiento y evaluado con la misma muestra de prueba, con 6 neuronas en la capa de entrada, 6, 9 y 15 neuronas incluidas en forma separada en la capa oculta y una neurona de salida.

Se puede apreciar que la mejor topología inicial del modelo de redes neuronales PERCEPTRON Multicapa esta definida por: 6 neuronas en capa de entrada, 15 neuronas en la capa oculta y una neurona de salida, debido al menor diferencia de porcentaje de errores incorrectos en la fase de prueba o validación con la de entrenamiento.

CUADRO N° 35
CLASIFICACION (RED MLP - 6 RATIOS SIN NORMALIZAR)

MUESTRA	OBSERVADO	PRONOSTICADO (6 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	74	6	92,5%
	Solvente	5	75	93,8%
	porcentaje global	49,4%	50,6%	93,1%
Prueba	Insolvente	13	1	92,9%
	Solvente	0	14	100,0%
	porcentaje global	46,4%	53,6%	96,4%
MUESTRA	OBSERVADO	PRONOSTICADO (9 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	75	5	93,8%
	Solvente	4	76	95,0%
	porcentaje global	49,4%	50,6%	94,4%
Prueba	Insolvente	13	1	92,9%
	Solvente	1	13	92,9%
	porcentaje global	50,0%	50,0%	92,9%
MUESTRA	OBSERVADO	PRONOSTICADO (15 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	75	5	93,8%
	Solvente	7	73	91,3%
	porcentaje global	51,3%	48,8%	92,5%
Prueba	Insolvente	13	1	92,9%
	Solvente	1	13	92,9%
	porcentaje global	50,0%	50,0%	92,9%
Variable dependiente: CONDICION (Solvente o Insolvente)				

Fuente: Elaboración Propia

CUADRO N° 36
RESUMEN DEL MODELO
SUMA DE ERRORES CUADRATICOS Y PORCENTAJE DE PRONÓSTICOS
(RED MLP - 6 RATIOS SIN NORMALIZAR)

Numero de Neuronas		6	9	15
Entrenamiento	Suma de errores cuadráticos	7,841	7,751	8,983
	Porcentaje de pronósticos incorrectos	6,9%	5,6%	7,5%
Prueba	Suma de errores cuadráticos	0,593	0,788	1,242
	Porcentaje de pronósticos incorrectos	3,6%	7,1%	7,1%

El siguiente cuadro N° 37, presenta un resumen de la importancia de los ratios financieros a la hora de identificar la solvencia empresarial y la vez esta relacionado a lo mencionado en el marco teórico, observándose al ratio solvencia patrimonial (Raz Pat) el de mayor importancia.

CUADRO N° 37
IMPORTANCIA DE LOS RATIOS FINANCIEROS
(RED MLP - 6 RATIOS SIN NORMALIZAR)

RATIOS	NUMEROS DE NEURONAS EN CAPA OCULTA E IMPORTANCIA DE LOS RATIOS FINANCIEROS		
	6	9	15
Raz Corr	45,8%	27,0%	41,5%
Prub Aci	9,8%	18,6%	13,5%
Raz End	68,2%	64,6%	67,2%
Raz Pat	100,0%	100,0%	100,0%
RAF	29,7%	33,6%	50,2%
RAT	42,5%	15,3%	12,0%

Fuente: Elaboración Propia

Resultados con las variables de entrada (6 ratios financieros) normalizados

En forma similar se procedió con el mismo análisis, utilizando una topología diferente a la establecida al modelo anterior, con los datos de entrada normalizados de las 188 empresas. En el cuadro N° 38 se muestra los resultados más significativos obtenidos, en las distintas topologías de la fase de entrenamiento y prueba, con 6 neuronas en la capa de entrada, con 6,15

y 24 neuronas incorporadas en forma separada en la capa oculta y una neurona de salida.

Se puede apreciar que en las topologías establecidas existe una similitud en los resultados obtenidos, en comparación con la anterior topología realizada con 6 ratios financieros sin normalizar.

CUADRO N° 38
CLASIFICACION (NUMERO DE NEURONAS EN LA CAPA OCULTA)
(RED MLP - 6 RATIOS NORMALIZADOS)

MUESTRA	OBSERVADO	PRONOSTICADO (6 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	74	6	92,5%
	Solvente	7	73	91,3%
	porcentaje global	50,6%	49,4%	91,9%
Prueba	Insolvente	13	1	92,9%
	Solvente	1	13	92,9%
	porcentaje global	50,0%	50,0%	92,9%
MUESTRA	OBSERVADO	PRONOSTICADO (15 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	74	6	92,5%
	Solvente	6	74	92,5%
	porcentaje global	50,0%	50,0%	92,5%
Prueba	Insolvente	13	1	92,9%
	Solvente	1	13	92,9%
	porcentaje global	50,0%	50,0%	92,9%
MUESTRA	OBSERVADO	PRONOSTICADO (24 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	69	11	86,3%
	Solvente	3	77	96,3%
	porcentaje global	45,0%	55,0%	91,3%
Prueba	Insolvente	13	1	92,9%
	Solvente	1	13	92,9%
	porcentaje global	50,0%	50,0%	92,9%

Variable dependiente: CONDICION (Solvente o Insolvente)

Fuente: Elaboración Propia

De las tres topologías la que mejor identifica la solvencia o insolvencia es la que presenta 6 neuronas en la capa de entrada, 15 neuronas en la capa oculta y una en la capa de salida.

Podemos ver que el porcentaje de pronósticos incorrectos es prácticamente igual en las muestras de prueba, y la mínima suma de errores cuadráticos en la muestra de prueba es la que tiene dentro de la capa oculta 15 neuronas (1.086). Así mismo, el porcentaje de pronósticos incorrectos es aproximadamente igual en las muestras de entrenamiento (7.50%) y prueba (7,10 %), lo que confirma el proceso de validación cruzada. Ver cuadro N° 39.

**CUADRO N° 39
RESUMEN DEL MODELO
SUMA DE ERRORES CUADRATICOS Y PORCENTAJE DE PRONÓSTICOS
(RED MLP - 6 RATIOS NORMALIZADOS)**

Numero de Neuronas		6	15 (Optimo)	24
Entrenamiento	Suma de errores cuadráticos	9,506	9,450	10,741
	Porcentaje de pronósticos incorrectos	8,1%	7,5%	8,8%
Prueba	Suma de errores cuadráticos	1,301	1,086	1,593
	Porcentaje de pronósticos incorrectos	7,1%	7,1%	7,1%

Fuente: Elaboración Propia

Análogamente como en los casos anteriores, el cuadro N° 40 presenta el ratio de mayor importancia a la hora de identificar la solvencia empresarial, es el ratio financiero razón de endeudamiento total (Raz End), coincidiendo en las tres configuraciones.

CUADRO N° 40
IMPORTANCIA DE LOS RATIOS FINANCIEROS
(RED MLP - 6 RATIOS NORMALIZADOS)

RATIOS	NUMEROS DE NEURONAS EN CAPA OCULTA E IMPORTANCIA DE LOS RATIOS FINANCIEROS		
	6	15	24
Raz Corr	39,1%	42,6%	55,0%
Prub Aci	44,1%	57,5%	54,4%
Raz End	100,0%	100,0%	100,0%
Raz Pat	72,2%	69,2%	65,3%
RAF	66,8%	65,1%	8,9%
RAT	55,0%	50,0%	77,3%

Fuente: Elaboración Propia

4.3.3. Redes neuronales artificiales (Función de Base Radial), utilizando 14 ratios financieros.

El modelo de red utilizado en esta etapa del experimento, es conocido como la Función de Base Radial (FBR). Su arquitectura es unidireccional para aproximación funcional, similar al PERCEPTRÓN Multicapa con la diferencia de su capa intermedia u oculta que tiene una estructura radial, es decir, una función supervisada con patrón de salida que realiza clasificaciones a partir de elipses o hiperelipses que parten el espacio de entrada de datos.

Para el desarrollo de este modelo se contó igualmente con dos conjuntos de datos:

Conjunto de entrenamiento	→	160 empresas
Conjunto de validación	→	28 empresas

Con respecto al pre-procesamiento de la data se tomará en cuenta datos sin normalizar y normalizados.

La capa de entrada tendrá 14 neuronas en función al número de ratios financieros. Para la selección del número de neuronas en la capa oculta, teniendo en cuenta el espacio de entrada, se iniciará con un número reducido de neuronas o nodos gaussianos y si algún patrón de entrada no activa en suficiente medida ninguna de las neuronas ocultas se considerará aumentar una nueva, por lo cual dicho número de neuronas ocultas se hizo variar entre 7 y 21. La capa de salida al igual que el PERCEPTRÓN Multicapa contará con una sola neurona que representa una clasificación binaria, 1 para las empresas “Solventes” y 0 para las empresas “Insolventes”. En el cuadro N° 41 muestra los parámetros generales para la ejecución del experimento con la red de base radial y en el cuadro N° 42 la información de la red.

**CUADRO N° 41
PARÁMETROS DE RED DE BASE RADIAL**

Función de Activación Capa oculta	Softmax
Factor para ancho de las funciones de base radial	$1 + 0.1(14) = 2.4$
Función de Activación Capa Salida	Identidad

Fuente: Elaboración Propia

Para determinar el número de neuronas de la capa oculta óptima comenzaremos con un mínimo de neuronas, luego se observará el porcentaje de aciertos incorrectos en la fase de entrenamiento junto a la minimización de la suma de errores cuadráticos. Para minimizar el error, se aumentará más neuronas. Con estas consideraciones se comenzará con un número de 7, 14 y 21 neuronas. A continuación se mostrará los resultados de los experimentos con los datos normalizados y sin normalizar.

Resultados con las variables de entrada (ratios financieros) sin normalizar

El cuadro N° 42 muestra información sobre la red de base radial con la que se va a experimentar, las variables de entrada (independientes), la de salida

(dependiente), las funciones de activación de cada capa y sus números de neuronas respectivamente.

**CUADRO N° 42
INFORMACIÓN SOBRE LA RED
(RED FBR - 14 RATIOS SIN NORMALIZAR)**

Capa de entrada	Variables	1. Índice Liquidez		Raz Corr
		2. Prueba Acida		Prub Aci
		3. Endeudamiento Total		Raz End
		4. Solvencia Patrimonial		Raz Pat
		5. Índice de Capitalización		Ind Cap
		6. Cobertura del Activo Fijo		Raz Cob AF
		7. Plazo Promedio de Cobranza		PPC
		8. Plazo de Inmovilización de Existencias		PIE
		9. Rotación del Activo Fijo		RAF
		10. Rotación del Activo Total		RAT
		11. Costo de Ventas a Ventas		CV/V
		12. Rentabilidad Sobre el Capital Propio		ROE
		13. Rentabilidad Sobre la Inversión		ROA
		14. Rentabilidad Sobre las Ventas		RSV
	Método de cambio de escala de las Variables		Ninguna	
Capa oculta	Número de unidades		7 - 14 - 21	
	Función de activación		Softmax	
Capa de salida	Variables dependientes	1	CONDICION	
	Número de unidades		1	
	Función de activación		Identidad	
	Función de error		Suma de cuadrados	

Fuente: Elaboración Propia

En los cuadros N° 43 y N° 44 se muestra los datos de la clasificación con 7, 14 y 21 neuronas, y se observa que el modelo tiene una mejor performance con 21 neuronas en la capa oculta, en función a la diferencia entre el porcentajes de pronósticos incorrectos entre la fase de entrenamiento y prueba es mínima.

CUADRO N° 43
CLASIFICACION (NUMERO DE NEURONAS EN LA CAPA OCULTA)
(RED FBR -14 RATIOS SIN NORMALIZAR)

MUESTRA	OBSERVADO	PRONOSTICADO (7 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	46	34	57,5%
	Solvente	16	64	80,0%
	porcentaje global	38,8%	61,3%	68,8%
Prueba	Insolvente	11	3	78,6%
	Solvente	0	14	100,0%
	porcentaje global	39,3%	60,7%	89,3%
MUESTRA	OBSERVADO	PRONOSTICADO (14 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	48	32	60,0%
	Solvente	14	66	82,5%
	porcentaje global	38,8%	61,3%	71,3%
Prueba	Insolvente	9	5	64,3%
	Solvente	1	13	92,9%
	porcentaje global	35,7%	64,3%	78,6%
MUESTRA	OBSERVADO	PRONOSTICADO (21 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	insolvente	56	24	70,0%
	Solvente	13	67	83,8%
	porcentaje global	43,1%	56,9%	76,9%
Prueba	insolvente	9	5	64,3%
	Solvente	1	13	92,9%
	porcentaje global	35,7%	64,3%	78,6%

Variable dependiente: CONDICION (Solvente o Insolvente)

Fuente: Elaboración Propia

CUADRO N° 44
RESUMEN DEL MODELO
SUMA DE ERRORES CUADRATICOS Y PORCENTAJE DE PRONÓSTICOS
(RED FBR - 14 RATIOS SIN NORMALIZAR)

Numero de Neuronas		7	14	21
Entrenamiento	Suma de errores cuadráticos	32,052	29,864	25,478
	Porcentaje de pronósticos incorrectos	31,3%	28,8%	23,1%
Prueba	Suma de errores cuadráticos	3,508	4,394	4,814
	Porcentaje de pronósticos incorrectos	10,7%	21,4%	21,4%

Fuente: Elaboración Propia

CUADRO N° 45
IMPORTANCIA DE LOS RATIOS FINANCIEROS
(RED MLP - 14 RATIOS SIN NORMALIZAR)

RATIOS	NUMEROS DE NEURONAS EN CAPA OCULTA E IMPORTANCIA DE LOS RATIOS FINANCIEROS		
	7	14	21
Raz Corr	,7%	1,1%	1,3%
Prub Aci	,7%	1,1%	1,2%
Raz End	2,9%	3,4%	4,8%
Raz Pat	42,9%	31,9%	60,1%
Ind Cap	37,5%	27,1%	32,9%
Raz Cob AF	100,0%	35,0%	63,0%
PPC	91,0%	100,0%	83,8%
PIE	52,4%	53,3%	100,0%
RAF	70,4%	71,3%	75,8%
RAT	2,4%	2,8%	3,1%
CV/V	1,1%	1,5%	1,3%
ROE	54,2%	41,1%	50,8%
ROA	6,7%	7,1%	12,0%
RSV	69,2%	65,3%	66,2%

Fuente: Elaboración Propia

Esta configuración elegida carece de validez debido a que existe una diferencia significativa entre los porcentajes de casos correctos en las muestras de entrenamiento y prueba en los grupos de solvencia e insolvencia, donde se puede apreciar en el siguiente esquema:

Entrenamiento:	
Insolvente	70,0%
Solvente	83,8%
Prueba:	
Insolvente	64,3%
Solvente	92,9%

Además, la desventaja de usar datos sin normalizar se observa en el cuadro N° 45 porque la red está discriminando con ratios que no tienen una significancia relevante tal es el caso el ratio plazo promedio de cobranza (PPC) y plazo de inmovilización de existencias (PIE), lo que no está de acuerdo con la definición establecida de solvencia e insolvencia empresarial.

Resultados con las variables de entrada (ratios financieros) normalizados

Con los cuadros N° 46 y 47 se puede determinar que el mejor número de neuronas para la capa oculta de la red de función de base radial es de 7 neuronas, en forma similar al caso anterior se establece como la mejor topología el criterio de la menor diferencia del porcentaje de aciertos incorrectos así como la menor suma de errores cuadráticos.

CUADRO N° 46
CLASIFICACION (NUMERO DE NEURONAS EN LA CAPA OCULTA)
(RED FBR - 14 RATIOS NORMALIZADOS)

MUESTRA	OBSERVADO	PRONOSTICADO (7 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	insolvente	69	11	86,3%
	Solvente	17	63	78,8%
	porcentaje global	53,8%	46,3%	82,5%
Prueba	insolvente	12	2	85,7%
	Solvente	3	11	78,6%
	porcentaje global	53,6%	46,4%	82,1%
MUESTRA	OBSERVADO	PRONOSTICADO (14 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	insolvente	74	6	92,5%
	Solvente	10	70	87,5%
	porcentaje global	52,5%	47,5%	90,0%
Prueba	insolvente	13	1	92,9%
	Solvente	2	12	85,7%
	porcentaje global	53,6%	46,4%	89,3%
MUESTRA	OBSERVADO	PRONOSTICADO (21 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	insolvente	74	6	92,5%
	Solvente	8	72	90,0%
	porcentaje global	51,3%	48,8%	91,3%
Prueba	insolvente	13	1	92,9%
	Solvente	3	11	78,6%
	porcentaje global	57,1%	42,9%	85,7%

Variable dependiente: CONDICION (Solvencia o Insolvencia)

Fuente: Elaboración Propia

**CUADRO N° 47
RESUMEN DEL MODELO
SUMA DE ERRORES CUADRATICOS Y PORCENTAJE DE PRONÓSTICOS
(RED FBR - 14 RATIOS NORMALIZADOS)**

Numero de Neuronas		7 (Óptimo)	14	21
Entrenamiento	Suma de errores cuadráticos	21,158	13,781	12,640
	Porcentaje de pronósticos incorrectos	17,5%	10,0%	8,8%
Prueba	Suma de errores cuadráticos	3,913	2,316	2,241
	Porcentaje de pronósticos incorrectos	17,9%	10,7%	14,3%

Variable dependiente: CONDICION (Solvente o Insolvente)
Fuente: Elaboración Propia

**CUADRO N° 48
IMPORTANCIA DE LOS RATIOS FINANCIEROS
(RED FBR - 14 RATIOS NORMALIZADOS)**

RATIOS	NUMEROS DE NEURONAS EN CAPA OCULTA E IMPORTANCIA DE LOS RATIOS FINANCIEROS		
	7	14	21
Raz Corr	100,0%	95,3%	100,0%
Prub Aci	72,2%	59,1%	68,4%
Raz End	87,3%	79,2%	79,0%
Raz Pat	49,0%	47,0%	64,8%
Ind Cap	51,4%	48,4%	64,6%
Raz Cob AF	54,9%	52,6%	62,6%
PPC	66,6%	55,3%	80,7%
PIE	61,5%	71,6%	74,9%
RAF	61,7%	70,9%	59,5%
RAT	84,7%	87,6%	81,0%
CV/V	64,0%	51,6%	71,0%
ROE	62,1%	100,0%	80,0%
ROA	64,4%	67,3%	89,3%
RSV	59,5%	47,1%	58,8%

Fuente: Elaboración Propia

El cuadro N° 48 muestra que al normalizar los datos mejora la calidad de identificación, por el hecho de que toma como ratios más importantes para la discriminación el índice corriente (Raz Corr), el endeudamiento total (Raz End) y la prueba ácida (Prub Aci) y esto sustenta la elección de 14 neuronas para la capa oculta de la red de función de base radial.

4.3.4. Redes neuronales artificiales (Función de Base Radial), con 6 ratios como entradas a la red.

Con el fin de mejorar el porcentaje de aciertos correctos se eligen los ratios financieros más relevantes, por lo que se centra en utilizar como variables de ingreso, los 6 ratios seleccionados por el estadístico de la razón F el cual revela que existen diferencias de medias entre los dos grupos de solvencia e insolvencia en las variables; solvencia patrimonial (Raz Pat), endeudamiento total (Raz End), prueba ácida (Prub Aci), índice corriente (Raz Corr), rotación del activo fijo (RAF) y rotación del activo total (RAT). Los parámetros de la red son las mismas que se utilizó en la etapa 3.

Resultados con las variables de entrada (ratios financieros) sin normalizar

Las variables de entrada y salida así como las funciones de activación se muestran en el cuadro N° 49.

Los otros parámetros como el factor de anchura de la función son las mismas de los modelos utilizados anteriormente, con respecto a la red de función de base radial.

Con los datos sin normalizar se observa que el número de neuronas óptimo es de 14 unidades, con 90% de aciertos globales en la fase de entrenamiento y 92.9% en la fase de prueba, tal como se aprecia en los cuadros N° 50 y N° 51.

Para la elección del número de neuronas se tuvo cuenta el criterio la diferencia del porcentaje de aciertos correctos e incorrectos así como la menor suma de errores cuadráticos.

**CUADRO N° 49
INFORMACIÓN SOBRE LA RED
(RED FBR - 6 RATIOS SIN NORMALIZAR)**

Capa de entrada	Variables	1.- Índice Corriente	Raz Corr
		2.- Endeudamiento Total	Raz End
		3.- Prueba Acida	Prub Aci
		4.- Rotación del Activo total	RAT
		5.- Solvencia Patrimonial	Raz Pat
		6.- Rotación activo fijo	RAF
Capa oculta	Número de unidades		7 -14 -21
	Función de activación		Softmax
Capa de salida	Variables dependientes	1	CONDICION
	Número de unidades		1
	Función de activación		Identidad
	Función de error		Suma de cuadrados

Fuente: Elaboración Propia

CUADRO N° 50
CLASIFICACION (NUMERO DE NEURONAS EN LA CAPA OCULTA)
(RED FBR - 6 RATIOS SIN NORMALIZAR)

MUESTRA	OBSERVADO	PRONOSTICADO (7 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	70	10	87,5%
	Solvente	9	71	88,8%
	Porcentaje global	49,4%	50,6%	88,1%
Prueba	Insolvente	13	1	92,9%
	Solvente	1	13	92,9%
	Porcentaje global	50,0%	50,0%	92,9%
MUESTRA	OBSERVADO	PRONOSTICADO (14 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	75	5	93,8%
	Solvente	11	69	86,3%
	Porcentaje global	53,8%	46,3%	90,0%
Prueba	Insolvente	13	1	92,9%
	Solvente	1	13	92,9%
	Porcentaje global	50,0%	50,0%	92,9%
MUESTRA	OBSERVADO	PRONOSTICADO (21 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	74	6	92,5%
	Solvente	12	68	85,0%
	Porcentaje global	53,8%	46,3%	88,8%
Prueba	Insolvente	13	1	92,9%
	Solvente	1	13	92,9%
	Porcentaje global	50,0%	50,0%	92,9%

Variable dependiente: CONDICION (Solvente o Insolvente)
Fuente: Elaboración Propia

**CUADRO N° 51
RESUMEN DEL MODELO
SUMA DE ERRORES CUADRATICOS Y PORCENTAJE DE PRONÓSTICOS
(RED FBR - 6 RATIOS SIN NORMALIZAR)**

NUMERO DE NEURONAS		7	14 Optimo	21
Entrenamiento	Suma de errores cuadráticos	13,956	12,808	12,166
	Porcentaje de pronósticos incorrectos	11,9%	10,0%	11,3%
Prueba	Suma de errores cuadráticos	2,041	1,659	2,714
	Porcentaje de pronósticos incorrectos	7,1%	7,1%	7,1%

Fuente: Elaboración Propia

Para analizar el resultado anterior, se observa que esta configuración identifica mejor al grupo de insolventes debido a que la diferencia entre el porcentaje de casos correctos en la muestra de entrenamiento y prueba es mínima.

Entrenamiento:

Insolvente 93,8%

Solvente 86.3%

Prueba:

Insolvente 92.9%

Solvente 92.9%

En el cuadro N° 52, se analiza la importancia de la variable independiente (ratios) la cual muestra distintos grados según el número de neuronas en la capa oculta, lo que indica que no hay uniformidad de criterios al momento de discriminar la situación de solvencia o insolvencia empresarial, por lo que se realiza una normalización de los ratios financieros.

CUADRO N° 52
IMPORTANCIA DE LOS RATIOS FINANCIEROS
(RED FBR - 6 RATIOS SIN NORMALIZAR)

RATIOS	NUMEROS DE NEURONAS EN CAPA OCULTA E IMPORTANCIA DE LOS RATIOS FINANCIEROS		
	7	14	21
Raz Corr	36,5%	52,9%	43,9%
Prub Aci	33,1%	46,5%	39,1%
Raz End	100,0%	90,9%	79,0%
RAT	69,8%	46,6%	92,4%
RAF	73,1%	100,0%	100,0%
Raz Pat	47,2%	46,7%	42,7%

Fuente: Elaboración Propia

Resultados con las variables de entrada (6 ratios financieros) normalizados

Utilizando la misma configuración de la etapa anterior con la diferencia de que ahora se realiza el proceso de normalización de los 6 ratios, de las empresas que conforman la muestra de entrenamiento y prueba.

En el cuadro N° 53, se muestra los resultados obtenidos utilizando las diferentes configuraciones en este tipo de red, observando que el mejor resultado presenta la configuración de 6 neuronas en la capa de entrada, 14 neuronas en la capa oculta y 1 neurona de salida, donde se aprecia que tiene 88.8% de aciertos globales en la fase entrenamiento y 89.3% en la fase de prueba.

Cabe resaltar que al aumentar el número de neuronas en la capa oculta, no mejora la diferencia de porcentaje de aciertos correctos entre la fase de entrenamiento y la de prueba.

CUADRO N° 53
CLASIFICACION (NUMERO DE NEURONAS EN LA CAPA OCULTA)
(RED FBR - 6 RATIOS NORMALIZADOS)

MUESTRA	OBSERVADO	PRONOSTICADO (7 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	69	11	86,3%
	Solvente	10	70	87,5%
	Porcentaje global	49,4%	50,6%	86,9%
Prueba	Insolvente	13	1	92,9%
	Solvente	4	10	71,4%
	Porcentaje global	60,7%	39,3%	82,1%
MUESTRA	OBSERVADO	PRONOSTICADO (14 NEURONAS)		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	72	8	90,0%
	Solvente	10	70	87,5%
	Porcentaje global	51,3%	48,8%	88,8%
Prueba	Insolvente	13	1	92,9%
	Solvente	2	12	85,7%
	Porcentaje global	53,6%	46,4%	89,3%
MUESTRA	OBSERVADO	PRONOSTICADO (21 NEURONAS) OPTIMO		
		INSOLVENTE	SOLVENTE	PORCENTAJE CORRECTO
Entrenamiento	Insolvente	70	10	87,5%
	Solvente	8	72	90,0%
	Porcentaje global	48,8%	51,3%	88,8%
Prueba	Insolvente	13	1	92,9%
	Solvente	3	11	78,6%
	Porcentaje global	57,1%	42,9%	85,7%

Variable dependiente: CONDICION (Solvente o Insolvente)

Fuente: Elaboración Propia

**CUADRO N° 54
RESUMEN DEL MODELO
SUMA DE ERRORES CUADRATICOS Y PORCENTAJE DE PRONÓSTICOS
(RED FBR - 6 RATIOS NORMALIZADOS)**

Numero de Neuronas		7	14	21
Entrenamiento	Suma de errores cuadráticos	17,072	13,542	11,387
	Porcentaje de pronósticos incorrectos	13,1%	11,3%	11,3%
Prueba	Suma de errores cuadráticos	3,260	2,325	1,994
	Porcentaje de pronósticos incorrectos	17,9%	10,7%	14,3%

Fuente: Elaboración Propia

Observando los cuadros N° 53 y 54, determinamos como el número de neuronas de 14 para la capa oculta, donde un número mayor a este origina un aumento en la suma de cuadrática de errores y el porcentaje de pronósticos incorrectos.

**CUADRO N° 55
IMPORTANCIA DE LOS RATIOS FINANCIEROS
(RED FBR - 6 RATIOS NORMALIZADOS)**

RATIOS	NUMEROS DE NEURONAS EN CAPA OCULTA E IMPORTANCIA DE LOS RATIOS FINANCIEROS		
	7	14	21
Raz Corr	100,0%	100,0%	100,0%
Raz End	82,2%	93,7%	69,9%
Prub Aci	69,4%	76,7%	68,2%
RAT	72,4%	43,8%	45,6%
Raz Pat	55,2%	51,4%	76,7%
RAF	75,6%	76,0%	69,3%

Fuente: Elaboración Propia

Se valida la elección de tal número de neuronas porque como se ve en el cuadro N° 55 todos los ratios tienen una gran importancia y son uniformes en la discriminación de solvencia e insolvencia.

4.4. RESULTADOS

El resumen de la identificación de la solvencia o insolvencia de las empresas, realizadas mediante el método del análisis discriminante en sus dos etapas se presenta en el cuadro N° 56 y cuadro N° 57.

**CUADRO N° 56
RESULTADOS OBTENIDOS POR EL ANALISIS DISCRIMINATE
(14 ratios financieros)**

		Grupo al que pertenece	Grupo asignado por la función discriminante		Total
			Insolvente	Solvente	
Original	Numero de Empresas	Insolvente	67	13	80
		Solvente	6	74	80
	Porcentaje	Insolvente	83,75	16,25	100,00
		Solvente	7,50	92,50	100,00
Validación	Numero de Empresas	Insolvente	13	1	14
		Solvente	2	12	14
	Porcentaje	Insolvente	92,86	7,14	100,00
		Solvente	14,29	85,71	100,00

Fuente: Elaboración Propia

Puede observarse en el cuadro anterior que tasa de error con el modelo original considerando la muestra de 160 empresas, es de 11,87% $[(6+13)/160]$. Con respecto a la validación teniendo en cuenta 28 empresas la tasa de error es de 10,71% $[(2+1)/28]$.

**CUADRO N° 57
RESULTADOS OBTENIDOS POR EL ANALISIS DISCRIMINATE
(3 ratios financieros)**

		Grupo al que pertenece	Grupo asignado por la función discriminante		Total
			Insolvente	Solvente	
Original	Numero de Empresas	Insolvente	62	18	80
		Solvente	6	74	80
	Porcentaje	Insolvente	77,50	22,50	100,00
		Solvente	7,50	92,50	100,00
Validación	Numero de Empresas	Insolvente	6	8	14
		Solvente	0	14	14
	Porcentaje	Insolvente	42,86	57,14	100,00
		Solvente	0	100,00	100,00

Fuente: Elaboración Propia

De la misma forma se observa en el cuadro anterior que la tasa de error con el modelo original considerando la muestra de 160 empresas y utilizando solamente 3 ratios financieros, es de 15,00% $[(6+18)/160]$. Con respecto a la validación teniendo en cuenta 28 empresas la tasa error es de 28,57% $[(0+8)/28]$.

Podemos concluir que el modelo obtenido por el análisis discriminante, utilizando los 14 ratios financieros en la fase de entrenamiento es el que posee la menor tasa de error (11,87%) y el mayor porcentaje de aciertos (88,13%), como también, en la fase de validación o prueba la tasa de error (10,71%) y porcentaje de aciertos (89,29%), con respecto al modelo utilizando sólo 3 ratios financieros. Se puede anotar que los ratios financieros incluidos en el modelo, si bien algunos no cumplieron con el criterio de significancia individual en este experimento aplicado, ayudaron a mejorar la significancia global del modelo, lo que no deja de ser una propiedad importante en un modelo de clasificación.

El resumen de los resultados obtenidos utilizando los modelos de redes neuronales artificiales, se muestran a continuación:

En los cuadros N° 58 y N° 59 se presenta el porcentaje de aciertos considerando las configuraciones más significativas estudiadas. Analizando ambos modelos en sus fases de entrenamiento y prueba (validación), podemos afirmar que el modelo que identifica la solvencia empresarial con mayor eficiencia es el modelo de red neuronal PERCEPTRON Multicapa (6 - 15 -1), dicho modelo con las variables de entrada normalizadas y sin normalizar, presenta el mismo porcentaje de pronósticos correctos en la fase de entrenamiento como en el de prueba. Diferenciándose en la selección del ratios de mayor importancia y en la suma de errores cuadráticos, como se puede apreciar en el cuadro N° 60.

CUADRO N° 58
RESULTADOS OBTENIDOS POR EL CON EL MODELO PERCEPTRON Multicapa

Configuración	Datos Normalizado	Aciertos	
		Entrenamiento (160 empresas)	Prueba (28 empresas)
PERCEPTRON Multicapa (14, 14, 1) - (14 ratios)	NO	75,60%	82,10%
PERCEPTRON Multicapa (14, 28, 1) - (14 ratios)	SI	91,90%	92,90%
PERCEPTRON Multicapa (6, 15, 1) - (6 ratios)	NO	92,50%	92,90%
PERCEPTRON Multicapa (6, 15, 1) - (6 ratios)	SI	92,50%	92,90%

Fuente: Elaboración Propia

Los resultados más significativos obtenidos, utilizando el modelo Función de Base Radial, fueron:

CUADRO N° 59
RESULTADOS OBTENIDOS POR EL CON EL MODELO FUNCION DE BASE RADIAL

Configuración	Datos Normalizado	Aciertos	
		Entrenamiento (160 empresas)	Validación (28 empresas)
Función de Base Radial (14, 21, 1)	NO	76,90%	78,60%
Función de Base Radial (14, 7, 1)	SI	82,50%	82,10%
Función de Base Radial (6,14, 1)	NO	90,00%	92,90%
Función de Base Radial (6,14, 1)	SI	88,80%	89.30%

Fuente: Elaboración Propia

CUADRO N° 60
SUMA DE ERRORES CUADRATICOS Y PORCENTAJES DE PRONOSTICOS INCORRECTOS

Numero de Neuronas		MLP	MLP
		6-15-1 Sin Normal.	6-15-1 Normal.
Entrenamiento	Suma de errores cuadráticos	8,983	9,450
	Porcentaje de pronósticos incorrectos	7,5%	7,5%
Prueba	Suma de errores cuadráticos	1,242	1,086
	Porcentaje de pronósticos incorrectos	7,1%	7,1%

Fuente: Elaboración propia

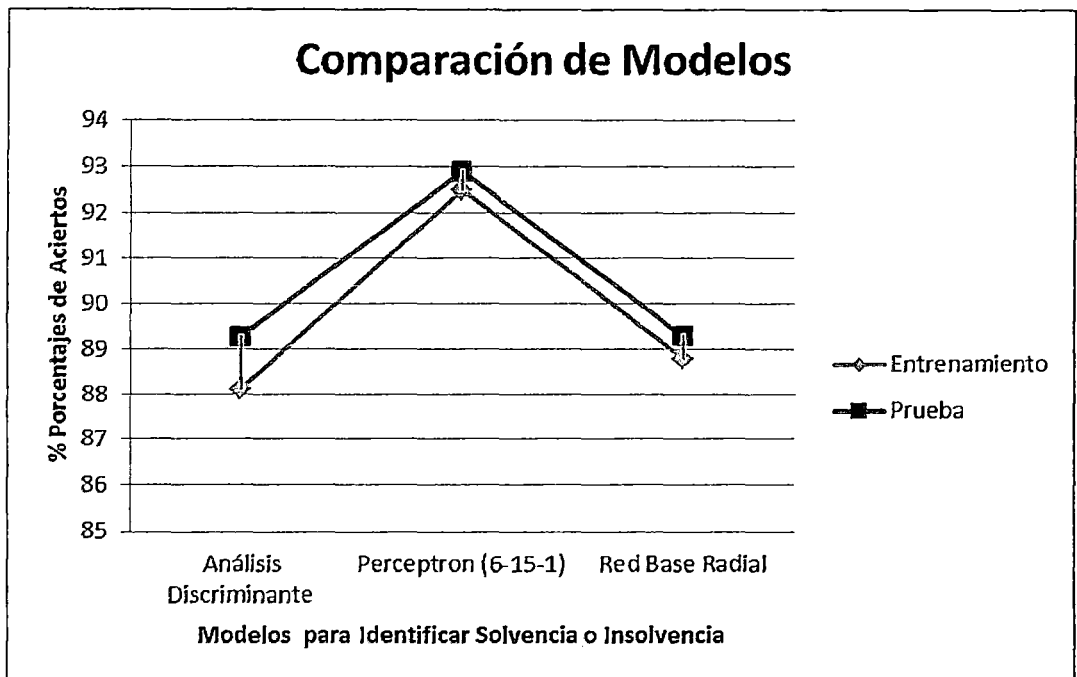


Figura N° 4.1 Grafico comparativo para identificar el modelo apropiado para la identificación de la situación financiera.

Así mismo, en comparación con los modelos establecidos en el análisis discriminante y de acuerdo con los hallazgos de la investigación (Ver Figura N° 4.1), se establece la superioridad del modelo de redes neuronales PERCENTRON Multicapa (6-15-1).

Para profundizar la capacidad predictoria de la red realizaremos un análisis con la curva COR (Características Operativas del Receptor) que proporciona una evaluación cuantitativa de la exactitud mediante al área bajo la curva, permitiendo describir que tan separadas están las distribuciones de la sensibilidad y la especificidad de una prueba de clasificación.

Del gráfico observamos que el punto de corte es de 0,5, que es visto como una diagonal, y las curvas tanto de las empresas clasificadas como solventes e insolventes están encima de la diagonal cercana al extremo superior izquierdo describiendo que hay una amplia separación entre las funciones de densidad de ambas.(Ver figura N° 4.2)

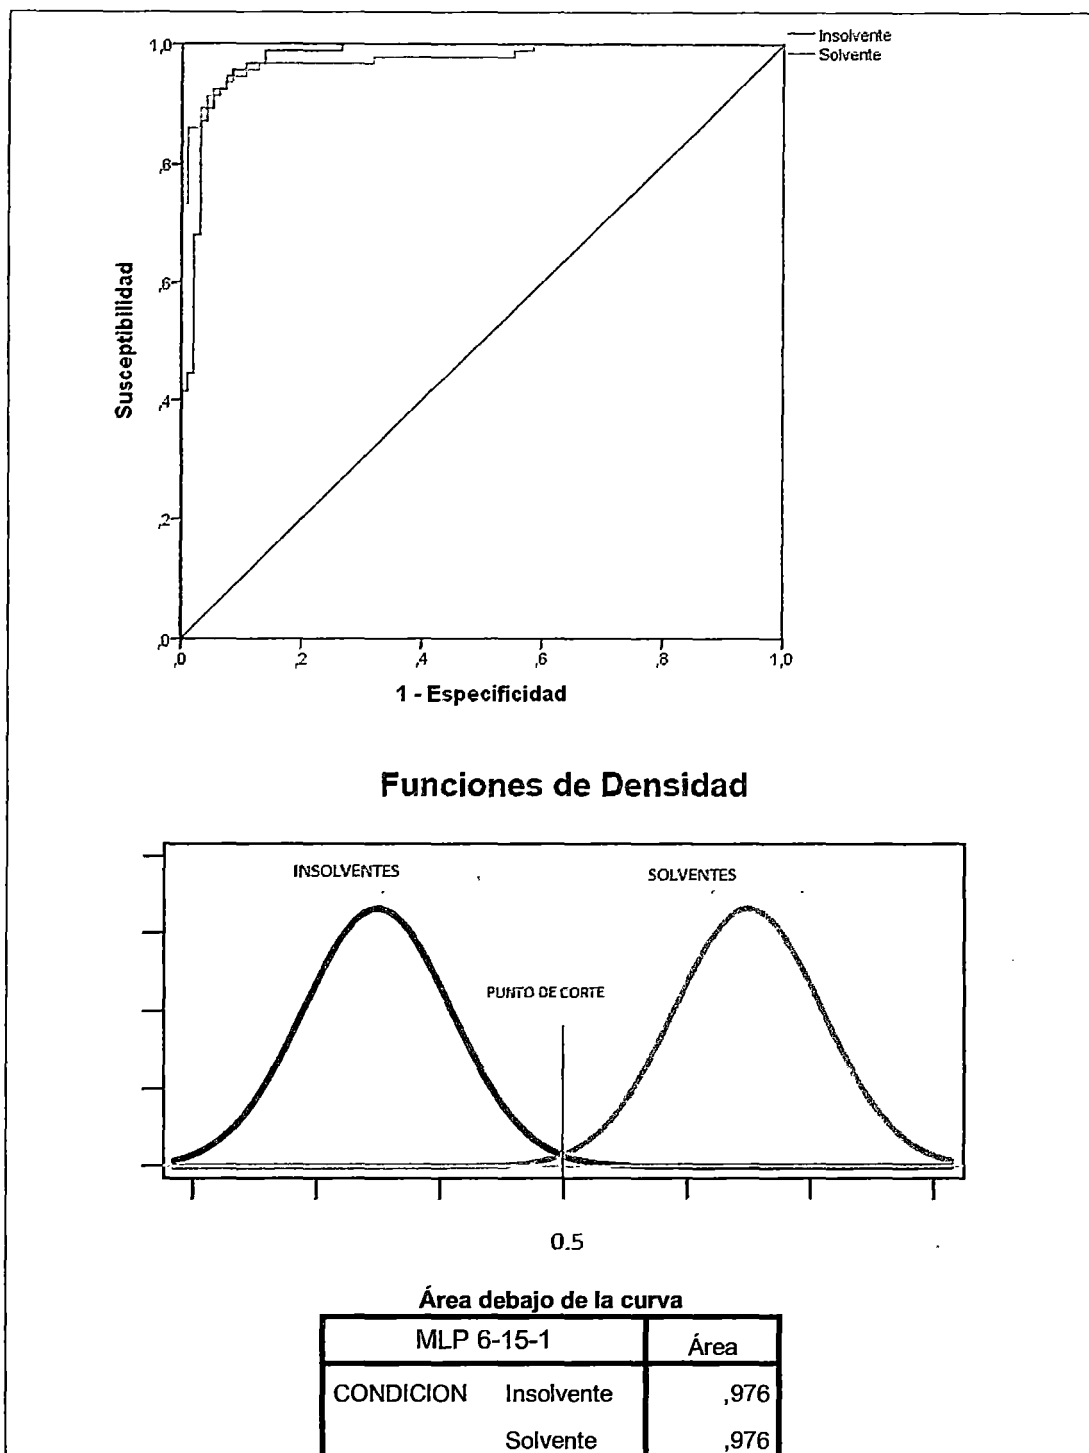


Figura N° 4.2 Gráfico Curva COR

El Área Bajo la Curva ROC (Area Under the Curve, AUC) estima la capacidad de distinguir o de “discriminar” entre dos grupos, que para nuestro modelo obtenemos un área igual a 0,976, mostrando que tiene una alta pseudoprobabilidad de clasificar al 97,6% de las empresas solvente como solventes así como al 97,67 % de empresas insolventes como insolventes.




Figura 4.3 Gráfico de pronósticos observados.

Para la variable dependiente categórica CONDICION, el gráfico de pronosticados por observados (ver figura N° 4.3) muestra diagramas de caja agrupados de pseudoprobabilidades pronosticadas para las muestras de entrenamiento y de prueba combinadas. El eje X corresponde a la categoría de insolventes y solventes observadas, y la leyenda corresponde a categorías pronosticadas. En nuestro análisis, el gráfico muestra que las cajas de los grupos de solventes e insolventes están distantes de la línea divisoria en el eje Y de 0.5, lo que indica que el modelo es bueno para

clasificar a los grupos solventes e insolventes, reforzando el análisis anterior con la Curva COR.

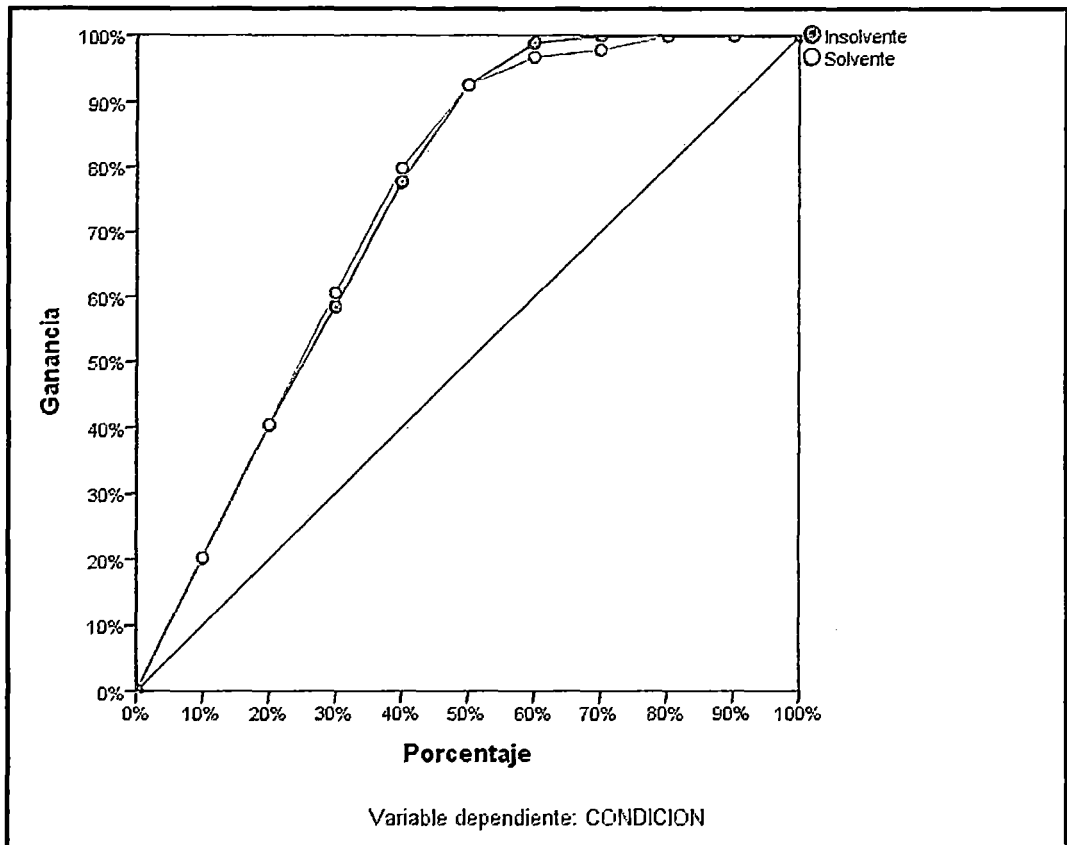


Figura nº 4.4 Gráfico de ganancias acumuladas

El gráfico de ganancias acumuladas muestra el porcentaje del número total de casos de una categoría dada “ganada” al dirigirse a un porcentaje del número total de casos. En la figura Nº 4.4 se observa que el quinto punto de la curva de insolventes (50%, 93%), se puede decir que de un grupo clasificado como insolventes se esperaría que el 50% de dicho grupo contiene realmente 93% de insolventes, es decir el modelo discrimina con buenos resultados ambos grupos.

Por último, la variable independiente que revela mayor importancia es la de endeudamiento total lo que indica que un aumento o disminución de esta variable impacta en la identificación de solvencia e insolvencia empresarial.

En el ranking de importancia se observa que están los ratios de solvencia, liquidez y de gestión. (Ver figura 4.5)




Figura N° 4.5 Grafico de la importancia de las variables independientes

4.5. DISCUSION DE LOS RESULTADOS

Algunos hallazgos que surgen de esta investigación para someter a prueba o escrutinio empírico las hipótesis planteadas al inicio y determinar si son apoyadas o refutadas, son:

Con respecto a la hipótesis general:

- De los dos modelos de redes neuronales artificiales utilizadas para el análisis de la identificación de la solvencia o insolvencia empresarial, en forma general, la que obtuvo un mayor porcentaje de aciertos es el modelo de las redes neuronales PERCEPTRON Multicapa; con una configuración de 6 neuronas en la capa de entrada, 15 neuronas en la

capa oculta y una neurona en la capa de salida, con los las variables de entrada (ratios financieros) normalizados.

- En las etapas de experimentación, considerando los 6 ratios financieros como variables de entrada y con el número de empresas del caso analizado, el modelo de redes neuronales artificiales PERCEPTRON Multicapa señalado en el punto anterior, muestran un comportamiento que refleja una mejor eficiencia en la identificación entre empresas “Solventes” o “Insolventes”, con respecto al modelo de redes neuronales artificiales de Función de Base Radial. El porcentaje de aciertos en predicción de la solvencia o insolvencia empresarial fue en la etapa de entrenamiento de 92,5 % y en la validación de 92,9% y con las variables de entrada normalizadas, mostrando también la menor suma de error cuadrático en la fase de entrenamiento y validación. (Ver cuadro N° 60)
- Podemos indicar que también ha demostrando su buen rendimiento y poderse utilizar independientemente del proceso de normalizar las variables de entrada (ratios financieros) tanto de la fase de entrenamiento como el de prueba siendo el caso del modelo de red PERCEPTRON Multicapa. (Ver cuadro N° 58).

Hipótesis específica N° 01

- Se establece la superioridad del modelo de redes neuronales artificiales (RNA), en cuanto a su capacidad de identificación de la solvencia o insolvencia empresarial, sobre el modelo del análisis discriminante tomado como referencia, esta centrada tradicionalmente a problemas lineales mientras que las redes neuronales artificiales están acostumbradas a tratar con problemas de categorías mal definidas, relaciones no lineales o datos con mucho ruido.

Hipótesis específica N° 02

- Ambos modelos, permiten determinar los ratios que influyen en la identificación de la solvencia o insolvencia empresarial, que se muestran en los cuadros de importancia de las variables de entrada.
- Cuando se introducen los ratios financieros hallados en el modelo del Análisis Discriminante, siguiendo el método Stepwise, como variables de entrada a las redes neuronales PERCEPTRON Multicapa, los resultados obtenidos no mejoran la eficiencia de los pronósticos de aciertos. En este caso se han utilizado los ratios con mayor significancia estadística, que a continuación mencionamos; solvencia patrimonial (Raz Pat), rotación del activo fijo (RAF), rotación del activo total (RAT), índice corriente (Raz Corr), prueba ácida (Prub Acid), endeudamiento total (Raz End). De esta forma, introducidos ellos como variables de entrada, se alcanzan valores muy importantes en los aciertos de la identificación de la solvencia con RNA. Esto se aprecia en los resultados obtenidos en la etapa 2 del experimento.
- Los mejores resultados obtenidos, tanto en el Análisis Discriminante como en las Redes Neuronales Artificiales, remarcan la importancia de algunas variables en la identificación de serios problemas financieros de las empresas. Estas variables son los ratios: índice corriente (Raz Corr), prueba ácida (Prub Acid), Endeudamiento total (Raz End), solvencia patrimonial (Raz Pat). Como también se aprecia en los cuadros de la importancia de los ratios financieros teniendo en cuenta la utilización de las neuronas en la capa oculta en la etapa 2 del experimento. La importancia de estos ratios en la explicación de la causa, deriva en gran medida de la capacidad de la empresa de generar fondos para atender los servicios de deudas y de sostener el costo del financiamiento en condiciones adecuadas, ya sea a través de fondos ajenos como de fondos propios.

CAPITULO V

CONCLUSIONES Y RECOMENDACIONES

5.1. CONCLUSIONES

Esta investigación se centró en la aplicación de Redes Neuronales Artificiales en la identificación de la solvencia en insolvencia empresarial, buscando compararlas con técnicas estadísticas más tradicionales utilizadas para resolver el mismo tipo de problemas, como es el caso del Análisis Discriminante Multivariante.

Si bien se sabe que un modelo de Red Neuronal Artificial no da información explícita sobre la importancia relativa de las distintas variables de entrada (predictores) ni sobre el grado de ajuste del modelo de datos, las técnicas estadísticas como el análisis de varianza (ANOVA) pueden complementarse adecuadamente en la solución de las tareas de clasificación o identificación.

Los ratios que tienen mayor efecto sobre como clasifica a las empresas en insolventes o solventes a través de la red en orden de importancia son:; endeudamiento total (Raz End), solvencia patrimonial (Raz Pat), rotación del activo fijo (RAF), prueba ácida (Prub Aci), rotación del activo total (RAT), índice corriente (Raz Corr). Como se puede notar de los seis ratios dos son de Liquidez, tres son de Solvencia y uno de Gestión confirmando que la solvencia e insolvencia esta vinculado con los bienes y recursos requeridos para resguardar las deudas adquiridas, aún cuando estos bienes no estén

referidos al efectivo, como también con la liquidez que debe contar una empresa para cumplir sus compromisos a corto plazo .a medida que se cumplen. Entonces se podría decir que una cantidad mayor del endeudamiento total indican una mayor probabilidad de causar la insolvencia, pero esta claro que se necesitaría usar información adicional contenida en otros ratios financieros.

Los ratios financieros seleccionados satisfacen las condiciones definidas para la insolvencia establecidas en nuestro marco teórico.

El análisis discriminante múltiple ofrece una solución única ante unos mismos datos, a diferencia del modelo de red neuronal no garantiza que la solución dada sea la óptima, pero mediante un proceso artesanal de distintas tipologías, número de unidades ocultas, funciones activación y reglas de aprendizaje se obtendrá una solución adecuada que incluso mejora la del modelo estadístico.

En la construcción del mejor modelo resulto ser la más efectiva el PERCEPTRON multicapa; con función de activación sigmoideal, con 6 neuronas en la capa de entrada, 15 neuronas en la capa oculta y una neurona en la capa de salida, logrando una asertividad de 92,9% en la identificación del solvencia o insolvencia empresarial.

La existencia de dos capas ocultas en el modelo PERCEPTRON Multicapa no mejora la acuciosidad de la identificación de la solvencia. La conclusión surge del resultado en el uso del algoritmo de aprendizaje Back-propagation; con dos capas ocultas no representa superiores resultados.

Los resultados obtenidos no pueden ser generalizados al sector financiero debido a que no se contó con empresas que se sometieron a un proceso económico y financiero, liquidación extrajudicial y quiebra de empresas

En los modelos de redes neuronales artificiales no se puede interpretar el grado de solvencia o insolvencia empresarial, debido a que el valor de pseudoprobabilidad $\approx (0, 1)$ no es una escala que indica cuan insolvente o solvente es una empresa.

5.2. RECOMENDACIONES

Para problemas demasiados complejos de clasificación, no existe una solución general que lo resuelva, lo que implica que deben ser divididos en partes y cada parte debe ser resuelto con una técnica apropiada, ya sean tradicionales, como a estadística o reglas heurísticas, o no tan convencionales como las redes neuronales artificiales.

Desarrollar modelos en forma conjunta entre estas áreas debería ser la tendencia de los trabajos en la actualidad, para complementarse adecuadamente en la solución de tareas de clasificación.

En el proceso de clasificación de las empresas en solvente o insolventes, es necesario inicialmente seleccionar adecuadamente las variables de entradas (ratios financieros), mediante la separación variables que no aportan en forma significativa al análisis conseguiremos eliminar información redundante y aumentaremos las opciones de obtener u modelo más adecuado.

Es necesario realizar estudios que adicionen la propiedad de interpretación y no solamente sean clasificación y predicción, incorporando nuevas técnicas heurísticas, lógica difusa, algoritmos genéticos y otros.

BIBLIOGRAFIA

CITAS BIBLIOGRAFICAS

Altman Edward I. (1968): "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy"; *The Journal of Finance*; September; pp. 589-609. Altman (1978): "Financial Applications of Discriminant Analysis a Clasification"; *Journal of Financial and Quantitative Analysis*; pp. 185-205.

Azoff, E. M., (1994), *Neural Network Time Series Forecasting of Financial Markets*, Inglaterra: John Wiley & Sons, pp. 50-51.

Barto, A. G.; Sutton, R. S.; Anderson, C. W. (1983). Neuron like elements that can solve difficult learning control problems. *IEEE Transactions on Systems, Man, and Cybernetics* 13, pp. 834-846.

Baum, E. B. y Haussler, D., (1988), *Neural Computation* 1, pp. 151-160.

Beaver William (1966): "Financial Ratios as Predictors of Failure"; *Empirical Research in Accounting: Selected Studies, Supplement to Journal of Accounting Research*, pp 71-111.

Beaver (1968): "Alternative Accounting Measures as Predictors of Failure"; *The Accounting Review*; January, pp. 112-122.

Brown, C.E. y O'Leary, D.E. (1995): "Introduction to artificial intelligence and expert systems", AI/ES Section of the American Accounting Association, (en Internet, <http://www.rutgers.edu/accounting/raw/aaa/aiet/aiethome.html>).

Castillo, E.; Gutiérrez, J. M.; Hadi A. S. (1998). Sistemas Expertos y Modelos de Redes Probabilísticas. Monografías de la Academia Española de Ingeniería, Madrid.

CONASEV: Indicadores Financieros Empresariales 1993-1994; Edición 1995; Lima, Perú.

CONASEV: Indicadores Financieros Empresariales 1995-1996; Edición 1997; Lima, Perú.

Del Rey Martínez, E. (1996): "Bankruptcy prediction in non-finance companies: an application based on artificial neural network models", en Sierra Molina, G. y Bonsón Ponte, E. (Eds.): Intelligent Systems in Accounting and Finance, Huelva, pp. 253-272.

Duda, R.O.; Shortliffe, E.H. (1983): "Expert systems research", Science, N° 220, april, pp. 261-268.

Dutta, S. y Shekhar, S. (1992): "Bond rating: a non conservative application of neural networks", en Neural Networks in Finance and Investing, Probus Publishing, Chicago, p. 443-450.

García-Ayuso Covarsí Manuel (1996): "Técnicas de Análisis Factorial Aplicadas al Análisis de la Información Financiera: Clasificaciones a priori, Hallazgos y Evidencia Empírica Española, "; Vol. XXV, N°. 86; enero-marzo; pp. 57-103.

Graveline, J. y Kokalari, M. (2008) "Credit risk", Working Paper, The Research Foundation of CFA Institute.

Grau Algueró, C. (1999): "La toma de decisiones a través de una red neuronal artificial borrosa", Proceedings of the VI International Meeting on Advances in Computational Management, Reus.

Gurney, K. (1995). Neural Nets Course. Brunel University. Internet <http://www.shef.ac.uk/psychology/gurney/notes/index.html>. Consultado el 08 de noviembre del 2009.

Haykin, S. (1999). Neural Networks: A comprehensive foundation. Prentice Hall 2nd edition.

Hecht-Nielsen, R. (1988), Applications of counterpropagation networks. Neural Networks, 1, 131-139.

Hernández, José Luis (2005). Análisis Financiero. Perú. Disponible en: www.gestiopolis.com/canales5/fin/anfinancier.htm. Consulta: 07 de Septiembre del 2010.

Ibarra Mares A. (2009). Desarrollo del Análisis Factorial Multivariable Aplicado al Análisis Financiero Actual. Disponible en [/www.eumed.net/libros/finanzas.htm](http://www.eumed.net/libros/finanzas.htm). Consulta 07 de diciembre del 2009.

Koh, H.C. y Tan, S.S. (1999): "A neural network approach to the prediction of going concern status", Accounting and Business Research, Vol. 29, Nº 3, pp. 211-216.

Kohonen, T. (1988). Self-Organizing Maps Springer Series in Information Sciences. Vol. 30, Springer, Berlin, Heidelberg, NY. pp. 236.

Kohonen, T. (2001). Self-Organizing Maps, third edition. Springer series in information sciences. Ed Springer. Helsinki University of Technology Neural networks Research Centre. pp. 286-310. Pitman, London.

Krishnamoorthy, C. S.; Rajeev, S. (1996). Artificial Intelligence and Expert Systems for Engineers. CRC Press, CRC Press LLC.

Lau, H.S.; Hing-Ling, A., y Gribbin, D.W. (1995): "On modelling cross sectional distributions of financial ratios", Journal of Business Finance & Accounting, vol. 22, N° 4, June, p. 521-549.

López González, E. y Flórez López, R. (1999): "El análisis de solvencia empresarial utilizando redes neuronales autoasociativas: el modelo Koh-León", Proceedings of the VI International Meeting on Advances in Computational Management, Reus.

Martikainen, T.; Perttunen, J.; Yli-Olli, P., y Gunasekaran (1995): "Financial ratio distribution irregularities: implications for ratio classification", European Journal of Operational Research, N° 80, pp. 34-44.

Martínez de Lejarza Esparducer, I. (1996): "Forecasting company failure: neural approach versus discriminant analysis. An application to Spanish insurance companies of the 80's", en Sierra Molina, G. y Bonsón Ponte, E. (Eds.): Intelligent Systems in Accounting and Finance, Huelva, pp. 169-186.

Minsky, M. y Papert, S.A. (1969): Perceptrons, MIT Press, Massachusetts (USA).

Moyer, Charles, R., Mcguigan, James, R., y Kretlow, William, J. (2000). Administración financiera contemporánea, México, Thomson.

Narendra, K. S.; Thathachar, M. A. (1974). Learning Automata: A Survey. IEEE Transactions on Systems, Man, and Cybernetics, vol. 14, p. 323-334.

Neural Network FAQ, Maintainer: Sarle, W. S., "How Many Hidden Units Should I Use?", Julio 27, 1996, Neural Network FAQ Part 1-7, Disponible en: <ftp://ftp.sas.com/pub/neural/FAQ3.html>, [1996, agosto 30].

Nilson, N. (1995). Principles of Artificial Intelligence. Nils Nilson Editors.

Nilson, N. (2001). Inteligencia Artificial. Una nueva síntesis. Mc Graw-Hill Interamericana de España.

Rees B. (1991). Financial Analysis. USA. Edit. Prentice Hall Inc.

Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review, 65, p. 386-408.

Rubio D., Pedro (2007). Manual de Análisis Financiero. España. Universidad de Málaga. Edición electrónica. Disponible en: <http://www.eumed.net/libros/2007a/255>. Consulta: 31 de Julio de 2008.

Rumelhart, D. E.; Hinton, G. E.; Williams, R. J. (1986). Learning internal representations by back-propagating errors in Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Eds. Cambridge, MA: MIT Press, vol. 1, p. 318-362.

S. Pandya and R. B. Macy (1996), Pattern Recognition with Neural Networks in C++. CRC Press.

Sánchez Tomás, A. (1993): "Sistemas expertos en Auditoría", Técnica Contable, N° 536- 537, pp. 529-544.

Serrano Cinca, C. y Martín del Brío, B. (1993): "Predicción de la quiebra bancaria mediante el empleo de redes neuronales artificiales", Revista Española de Financiación y Contabilidad, Vol. 22, Nº 74, pp. 153-176.

Serrano Cinca, C. y Gallizo Larraz, J.L. (1996): "Las redes neuronales artificiales en el tratamiento de la información financiera", Biblioteca Electrónica Ciberconta, (en Internet, <http://ciberconta.unizar.es/Biblioteca/Biblioteca.html>).

Shih, Y., (1994), Neural User's Guide, Cheshire Engineering Corporation, USA, p. 21.

Soldevilla, C. y Guillén, M. (1997): "Consumer credit scoring using artificial neural networks", en Sierra Molina, G. y Bonsón Ponte, E. (Eds.): Intelligent Technologies in Accounting and Business, Huelva, pp. 117-128.

Stuart J. R.; Norvig, P.; Canny, J. F.; Malik, J. M.; Douglas D. E. (1995). Artificial Intelligence A Modern Approach. Prentice Hall, Englewood Cliffs, New Jersey

Van Horne, James y Wachowicz, John (2003). Fundamentos de Administración Financiera (11ª ed.). México. Prentice Hall. 743 pp.

Watson, C.J. (1990): "Multivariate distributional properties, outliers, and transformation of financial ratios", Accounting Review, Vol. 65, Nº 3, July, pp. 662-695.

Widrow, B.; Hoff, M. E. (1960). Adaptive switching circuits. WESCON Convention Record. part 4, pp. 96-104. Reimpreso en Reprinted in Anderson and Rosenfeld (1988).

Zurada, J. M. (1992). Introduction to Artificial Neural Systems. West Publishing Company.

LIBROS

Anderson James A. (2007). Redes Neuronales. México. Edit. Alfaomega

Bernstein Leopold A. (1999). Financial Statement Analysis Theory. USA. Edit. Mc Graw Hill.

Bizquera R. Alzina; (1999). Introducción Conceptual al Análisis Multivariable. Tomo I y II; España, Edit. PPU.

Brigham, Eugene y Houston, Joel (2006); Fundamentos de Administración Financiera. 10ª Edic. México. Edit. Cengage Learning Editores.

Brealey, Richard A.; Myers, Stewart C. (1988). Principios de Finanzas Corporativas. 5ta. Edic. Madrid, España. Edit. Mc Graw-Hill.

Broomhead, D. and Lowe, D. (1988). Multivariable functional interpolation and adaptive networks. Complex Systems, 2:321–355

Fernandez, Pablo (1999); Valoración de Empresas. 1ra. Edic. Barcelona, España. Edit. Gestión 2000.

Forsyth, Juan A; (2004); Finanzas Empresariales, Rentabilidad y Valor. 1ra. Edic. Tarea Asociación Gráfica Educativa; Lima, Perú.

Flint, Pinkas (1999); Gestión de Empresas en Crisis. Técnicas de Reflotamiento. 1ra. Edic.; Lima; Publicaciones Flint Consulting Group.

Franco Concha, Pedro (2005): Evaluación de los Estados Financieros. Universidad del Pacífico Lima, Edit. Centro de Investigación.

Isasi, Pedro y Galván, León I. (2004); Redes Neuronales Artificiales, un enfoque práctico, Madrid. Edit. Pearson.

Gitman, Lawrence; Principios de Administración Financiera. (2003); 10ª Edic. México. Edit. Prentice Hall.

Lévy, J. P. y Varela, J. (2003); Análisis Multivariable para las Ciencias Sociales. 3ra. Edic. Madrid. Pearson Prentice Hall.

Lowe, D. Adaptive radial basis function nonlinearities and the problem of generalization. In: Proc. 1st EE Int. Conf. on Artificial Neural Networks (1989)

Martín del Brío, B. Y Sanz, A. (2002); Redes Neuronales y Sistemas Borrosos.. 2da Edic. Madrid. Edit. Ra-Ma.

Peréz, C, y Santín D. (2007): Minería de Datos. 1ra. Edic. España. Edit. Thomson.

Seidman, Claude (2001); Data Mining. 1ra. Edic. USA. Edit. Microsoft Corporation.

Ritchey, Ferris J. (2008). Estadística para las Ciencias Sociales. 2da Edic. México. Edit. Mac Graw Hill.

Rojas, I., Valenzuela, O., and Prieto, A. 1997 "Statistical Analysis of the Main Parameters in the Definition of Radial Basic Function Networks", Lecture Notes in Computer Science, Vol.1240. 882-891.

Ross, Stephen, A., Westerfield, W. Randolph y Jaffe, Jeffrey F. (1999); Finanzas Corporativas. 5a Edic. Edit. McGraw-Hill..

Van Horne, James y Wachowicz, John (2003); Fundamentos de Administración Financiera. 11ª Edic. México. Prentice Hall.

Viscione, Jerri A. (1993); Análisis Financiero. México, D. F. Limusa.

Warwick, K. An overview of neural networks in control applications. En: Neural Networks for Robotic Control, M. Zalzala. Ed. Prentice Hall, pp 1-25, 1995

Weston, J. F. y Brigham E. F. (1982); Fundamentos de Administración Financiera. 3ra.Edic. México. Edit. Interamericana.

Westwick C. A. (1987); Manual para la Aplicación de los Ratios de Gestión. España. Edit. Deusto.

TESIS

Bukovinsky David (1993). Cash Flow and Cash Position Measures in the Prediction of Business Failure: an Empirical Study. Tesis de la Universidad de Kentucky; pp. 205.

Caicedo D., Lizardo (2006); Factores Determinantes de la Crisis de la Insolvencia en el Perú. Tesis de la Universidad Nacional San Marcos. Facultad de Ciencias Económicas.

ANEXOS

ANEXO N° 01
INDICES (RAZONES) FINANCIERAS EMPRESAS INSOLVENTES

N°	EMPRESA	Liquidez		Solvencia				Gestión					Rentabilidad			SECTOR
		Raz Cor	Prub Acl	Raz End	Raz Pat	Ind Cap	Raz Cob AF	PPC	PIE	RAF	RAT	CV/V	ROE	ROA	RSV	
1	Fabricaciones Metálicas Guevara S.A	1,13	1,13	0,81	0,24	0,00	731,75	0,00	0,00	100,00	0,03	0,24	-1,67	-0,22	-12,19	1
2	Agroindustria Valle Verde S.A.	0,29	0,29	3,46	-0,71	0,00	0,00	782,24	0,00	0,00	0,51	0,96	1,43	-2,46	-6,92	1
3	Industrias Canciller S.A.	0,96	0,78	0,94	0,06	0,49	0,77	37,11	22,18	19,37	2,90	0,92	-3,55	-0,15	-0,07	1
4	Laboratorios AnakoIS S.A.	0,90	0,90	11,76	-0,91	-92,29	0,00	0,00	0,00	0,00	0,53	0,97	-0,27	2,02	5,42	1
5	Laboratorios Famur S.A.	0,24	0,09	2,67	-0,62	-0,13	-3,69	24,45	14,88	12,70	5,08	0,47	0,84	-0,98	-0,28	1
6	Industrial Allimira S.A.	0,99	0,52	0,88	0,14	0,78	1,04	56,88	147,84	1,36	0,73	0,70	-0,94	-0,08	-0,16	1
7	Cia Químico Industrial Pintel S.A.	0,88	0,16	0,92	0,09	-0,18	1,47	36,54	313,05	32,39	1,50	0,51	0,49	0,03	0,03	1
8	Sociedad Industrial Textil S.A.	2,54	1,32	1,59	-0,37	1,71	3,11	186,74	466,30	0,59	0,16	0,94	0,01	-0,01	-0,05	1
9	Textiles del Sur S.A.	0,27	0,11	1,14	-0,12	1,79	0,22	43,86	75,06	0,72	0,56	0,84	2,73	-0,26	-0,67	1
10	Curtiembre el Águila S.A.	0,03	0,02	3,83	-0,74	-0,22	-2,61	4,81	7,51	1,45	1,28	1,36	0,39	-0,76	-0,85	1
11	Fabrica de Tejidos La Unión S.A.	0,49	0,17	0,71	0,41	0,60	0,84	63,22	135,46	0,20	0,18	1,27	-0,41	-0,08	-0,68	1
12	Servicios de Impresión S.A.	0,05	0,05	23,16	-0,96	-0,23	0,00	0,00	0,00	0,00	0,00	0,00	0,10	-1,59	-0,84	1
13	Klimide S. A.	1,19	0,52	0,72	0,39	0,04	1,90	53,89	114,12	15,92	2,45	0,62	0,19	0,06	0,02	1
14	Gráfica M & R S. A.	0,03	0,03	8,35	-0,88	-0,09	-21,92	18,83	0,00	15,23	4,70	0,92	0,30	-1,43	-0,47	1
15	Plastisan S. A.	0,80	0,76	0,97	0,03	0,56	0,30	449,49	101,16	0,65	0,16	0,76	-7,61	-0,18	-1,54	1
16	Curtiembre Cocodrilo S. A.	0,79	0,35	2,67	-0,67	4,94	0,76	259,04	367,93	0,50	0,27	0,89	0,58	-0,67	-3,51	1
17	Compañía Embotelladora Huánuco S. A.	0,01	0,00	1,93	-0,48	0,00	-1,11	0,00	15,35	0,76	0,65	0,92	0,89	-0,58	-1,29	1
18	Ladrillera Jesús S. A.	0,08	0,03	10,17	-0,90	-0,77	-10,28	0,00	15,75	14,15	7,12	0,94	0,32	-2,01	-0,41	1
19	Mosalcos Pomabamba S. A.	0,79	0,16	1,52	-0,34	3,10	0,62	37,98	167,01	2,16	0,86	0,92	-0,43	0,17	0,26	1
20	Industrialización de Alimentos S. A. (INDALSA)	0,08	0,02	0,64	0,57	0,01	0,39	18,17	71,87	0,23	0,22	0,67	-0,26	-0,07	-0,45	1
21	Industrias Precisión S. A.	0,57	0,31	1,32	-0,24	1,73	13,12	194,93	24,94	9,83	0,33	0,91	0,33	-0,07	-0,33	1
22	Food Process S. A.	0,19	0,08	0,85	0,17	0,05	0,22	94,37	12,15	0,35	0,24	1,20	-1,09	-0,11	-0,66	1
23	Papeles Industriales S. A.	0,10	0,08	8,30	-0,88	0,00	-39,79	48,40	10,55	27,34	5,02	0,92	0,05	-0,24	-0,07	1
24	Polímeros y Adhesivos S. A. (POLYANSA)	0,04	0,04	22,94	-0,96	0,00	-237,95	0,00	0,00	0,00	0,00	0,00	0,02	-0,28	0,00	1
25	Poli San S. R. Ltda.	0,59	0,26	0,80	0,25	0,04	0,98	77,87	143,46	4,36	0,94	0,70	-0,41	-0,07	-0,09	1
26	B. B. Plast S. A.	0,44	0,22	1,63	-0,38	-0,51	-1,12	31,88	77,99	2,76	1,02	0,88	0,78	-0,34	-0,48	1
27	Cotton Export S. A.	0,54	0,51	1,81	-0,45	-0,01	-36,35	0,00	29,93	27,89	0,62	0,98	1,04	-0,59	-1,36	1
28	Tejidos Evy Land S. R. L.	0,01	0,01	4,27	-0,77	0,00	-3,95	469,99	0,00	0,06	0,05	11,14	1,35	-1,97	-92,99	1
29	Fabrica de Material Didáctico S. A.	0,91	0,90	4,59	-0,78	-39,12	-17,57	0,00	4,76	202,74	1,03	0,96	0,25	-0,64	-0,88	1
30	Productos Alimenticios PGPR S. R. L.	0,10	0,00	2,52	-0,60	-0,14	-1,75	0,00	46,23	1,29	0,98	0,92	0,44	-0,47	-0,68	1
31	Cobres Laminados S. A. (COBRELSA)	0,45	0,34	0,95	0,06	0,56	0,21	46,23	37,69	1,25	0,75	0,80	-4,54	-0,17	-0,33	1
32	Cartones Nacionales S. A. (CARTONSA)	0,07	0,00	0,95	0,06	0,92	1,02	0,00	0,00	0,00	0,00	0,00	-4,10	-0,15	0,00	1
33	Procesadora Yancay S. R. Ltda.	0,00	0,00	1,75	-0,43	-0,01	-0,75	0,00	0,00	0,02	0,02	0,85	0,00	0,00	-0,10	1
34	Industria Selva S. A. (INDULSEL)	0,41	0,26	1,16	-0,32	-0,12	-1,64	104,49	213,20	1,86	0,47	0,76	0,78	-0,25	-0,76	1
35	Industrias de Granos Alimenticios S. A. C. (IGASAC)	0,81	0,56	0,92	0,09	0,49	0,49	33,35	46,62	4,98	1,58	0,84	-1,09	-0,06	-0,06	1
36	Textiles Generales S. A.	1,22	1,14	0,88	0,14	0,48	2,75	21,48	20,31	15,80	1,32	0,76	-4,31	-0,36	-0,39	2
37	Amlcro S. A. (APPLE PERU)	1,03	0,71	0,89	0,13	0,10	1,37	20,57	108,84	11,28	1,02	0,84	-0,75	-0,06	-0,08	2
38	Cesar A. Peirano S. A.	0,52	0,10	5,20	-0,81	-5,21	-5,00	0,00	6084,28	1,33	0,18	0,23	0,13	-0,39	-3,11	2
39	Oechsle Cia. Comercial S. A.	1,00	0,64	1,55	-0,36	5,93	3,73	95,57	65,85	70,49	2,12	0,80	-1,80	0,71	0,47	2
40	Sociedad Andina Grandes Almacenes S. A. (SAGA)	0,49	0,31	1,91	-0,48	-1,69	-0,99	79,82	83,93	3,89	1,32	0,64	1,13	-0,70	-0,77	2
41	Los Pucci S. A.	2,20	1,12	0,43	1,32	0,00	18,86	197,27	707,44	21,16	0,84	0,28	0,10	0,06	0,09	2
42	Industriales Caltex S. A.	0,40	0,32	2,20	-0,55	0,00	-0,97	0,00	0,00	0,00	0,00	0,00	1,58	-1,33	0,00	2
43	Exportaciones Larhard S. A.	0,04	0,04	12,05	-0,92	0,00	-20,31	0,00	0,00	0,00	0,00	0,00	0,33	-2,57	0,00	2
44	Comercial de Soldadura Industriales S. A.	0,56	0,10	1,00	0,00	0,00	0,01	14,32	104,70	3,99	1,75	0,83	-139,12	-0,28	-0,23	2
45	Record Multimotriz S. A.	0,87	0,17	1,02	-0,02	1,49	0,22	8,00	217,32	9,04	1,43	0,65	18,20	-0,21	-0,21	2
46	Casa Crevani S. A.	0,38	0,02	1,91	-0,48	-0,58	-1,42	0,00	33,76	7,16	2,91	0,92	1,72	-1,09	-0,54	2

SECTOR	
INDUSTRIA	1
COMERCIO Y SERVICIO	2
EXTRACION	3

ANEXO N° 01
INDICES (RAZONES) FINANCIERAS EMPRESAS INSOLVENTES

N°	EMPRESA	Liquidez		Solvencia			Gestión				Rentabilidad			SECTOR		
		Raz Corr	Prub Acl	Raz End	Raz Pat	Ind Cap	Raz Cob AF	PPC	PIE	RAF	RAT	CV/V	ROE		ROA	RSV
47	Old Wood S. A. C.	0,00	0,00	2,47	-0,59	-0,06	-1,39	0,00	0,00	0,56	0,56	0,85	0,45	-0,49	-1,19	2
48	Agricultura para la Exportación E.I.R.L (AGREX)	0,79	0,47	1,27	-0,21	0,00	0,00	2,88	11,17	0,00	14,54	0,90	4,29	-0,80	-0,08	2
49	Comercial Centeno S. A.	0,85	0,19	0,91	0,10	0,85	0,91	11,64	74,32	2,53	1,68	0,76	0,21	0,02	0,01	2
50	Hogar S. A.	0,64	0,40	0,98	0,02	0,97	1,06	37,96	104,35	0,84	0,41	0,73	-11,15	-0,14	-0,48	2
51	Electrónica Latinoamerica S. A. C. (ELECTROL)	0,32	0,24	2,88	-0,65	0,00	-22,17	1284,72	204,69	1,18	0,10	1,04	0,71	-0,93	-13,29	2
52	Alpigo S. A.	0,91	0,81	0,94	0,07	0,77	0,80	45,32	21,60	10,26	3,35	0,89	-0,15	0,01	0,00	2
53	Karma Plastic S. A.	0,67	0,00	1,39	-0,28	-0,05	-4,65	0,00	132,43	28,06	2,28	1,07	1,74	-0,48	-0,30	2
54	Colonial Plastic S. A.	0,51	0,23	1,86	-0,46	-0,03	-13,06	13,08	27,55	92,26	5,86	1,07	1,33	-0,80	-0,19	2
55	Distribuidora Marca S. A. (DISMARCA)	3,12	1,68	1,81	-0,45	2,15	-11,97	4,67	8,96	287,40	17,06	0,98	1,37	-0,78	-0,07	2
56	Jeawel S. A.	0,41	0,37	2,52	-0,60	-0,07	-255,93	501,18	0,00	116,18	0,64	0,76	0,13	-0,14	-0,32	2
57	Minol Perú Corporation S. A.	0,92	0,50	0,93	0,08	0,43	0,65	96,87	172,48	6,56	1,27	0,59	-0,04	0,00	0,00	2
58	Despachos Internacionales Pacifico S. A.	0,78	0,51	1,28	-0,22	-0,18	-6,77	342,68	0,00	13,09	0,46	0,00	1,42	-0,28	-0,87	2
59	Empresa de Transporte Velásquez S. A.	0,29	0,29	1,39	-0,28	0,00	-0,67	0,00	0,00	1,42	0,82	1,18	0,90	-0,25	-0,43	2
60	Empresa de Transporte Unidos de Centro S. A. (ETUCSA)	1,48	1,37	1,17	-0,14	1,52	90,42	0,00	0,00	165,39	0,58	0,39	0,11	-0,01	-0,03	2
61	Japan Tuna del Perú S. A. Agentes Marítimos	1,17	1,17	0,89	0,45	0,02	1,58	41,06	0,00	3,63	0,73	0,00	-0,94	-0,20	-0,40	2
62	Empresa de Transporte Expreso Moderno E.I.R.L	0,39	0,39	0,92	0,09	0,00	0,13	0,67	0,00	0,57	0,37	0,42	0,31	0,02	0,07	2
63	Agropecuaria Pilar S. A.	3,21	0,46	1,62	-0,38	1,72	1,50	2,82	36,73	5,40	3,13	1,04	0,74	-0,32	-0,15	3
64	Avícola Rosmar S. A.	0,17	0,17	4,64	-0,78	0,00	-18,89	9,08	0,00	92,65	17,84	1,05	1,17	-2,98	-0,24	3
65	Del Agro Export Corp S. A.	0,47	0,23	1,22	-0,18	6,77	0,08	71,73	65,82	1,71	0,77	1,09	1,54	-0,23	-0,44	3
66	Agro Guayabito S. A.	0,57	0,24	0,68	0,47	0,49	0,87	138,82	582,67	0,14	0,10	0,66	0,00	0,00	0,01	3
67	Tramsa Agro S. A.	5,79	3,83	0,98	0,02	0,97	2,16	8,83	23,01	0,74	0,32	0,67	-6,11	-0,10	-0,12	3
68	GMC Ingenieros S. A.	1,67	0,97	0,52	0,91	0,00	3,77	38,81	0,00	34,99	4,41	0,00	-0,89	-0,30	-0,10	2
69	Velca S.A.C.	0,07	0,05	8,98	-0,89	-0,03	-21,08	0,00	0,00	0,04	0,02	0,00	-0,02	0,10	9,01	2
70	INSASA Contratista Generales S.A.C:	0,50	0,45	1,05	-0,04	0,00	-0,10	13,53	0,00	12,15	5,74	0,93	21,62	-0,70	-0,17	2
71	Compañía Minera Atalaya S. A.	0,85	0,00	1,18	-0,15	-0,02	-30,19	7,03	36,56	7,65	0,04	0,38	0,80	-0,10	-3,23	3
72	Compañía Minera Metalúrgica Huancayo S. A.	0,18	0,18	3,74	-0,73	0,00	-9,28	0,00	0,00	0,00	0,00	0,00	0,23	-0,44	0,00	3
73	Urín Cañ S. R. L.	0,13	0,13	7,22	-0,86	-0,01	-144,25	0,00	2,95	147,21	6,25	0,91	0,31	-1,35	-0,31	3
74	Pesquera Trece S. A.	0,76	0,76	1,08	-0,08	0,00	-0,46	11,89	0,00	0,70	0,12	0,71	0,40	-0,02	-0,27	3
75	Gerencia y Representaciones Pesqueras S. A. (GERPESA)	0,51	0,12	1,11	-0,10	2,73	0,12	51,84	67,34	0,91	0,48	0,76	2,13	-0,16	-0,49	3
76	Atlántic Unión S. A.	0,36	0,26	2,77	-0,64	0,00	18,00	2,03	2,03	0,73	1,00	0,29	-0,36	-0,70	-0,70	2
77	Agentes Aduaneros Universal S. A. (AGADUSA)	0,93	0,81	0,99	0,01	0,37	0,15	1590,67	0,00	1,86	0,15	0,00	-9,92	-0,05	-0,51	2
78	Servicios de Personalización Magnética S. A.	0,52	0,46	1,48	-0,32	0,00	-2,07	72,14	22,47	4,54	1,04	0,49	1,27	-0,42	-0,58	2
79	Horizontes S. A. Asesoría y Servicios Empresariales	0,60	0,44	1,57	-0,36	-0,13	-5,37	7,92	0,00	182,42	17,29	0,00	1,53	-0,62	-0,05	2
80	Hotel Perú S. A.	0,33	0,21	1,71	-0,41	0,00	-53,48	69,68	0,00	65,22	0,86	0,52	1,45	-0,72	-1,19	2
81	F & F Publicidad S. A.	0,06	0,06	15,09	-0,93	0,00	-104,31	0,00	0,00	0,00	0,00	0,00	2,17	-21,41	0,00	2
82	Industrias Texoro S. A. (INDUTEX)	0,04	0,04	12,37	-0,92	-0,03	-21,92	0,00	4,73	5,23	2,63	1,13	0,07	-0,52	-0,29	2
83	Inversiones Mira S. A.	0,85	0,80	1,43	-0,30	2,50	0,66	70,05	9,68	4,10	1,78	0,76	1,29	-0,64	-0,31	2
84	Cooperativa de Trabajo y Fomento de Empleo Atlas Ltda	0,35	0,25	2,84	-0,65	-0,01	-22,64	21,98	1,33	126,45	10,13	0,95	1,04	-1,33	-0,19	2
85	Cla. Servicios Integral S. A.	0,94	0,65	0,87	0,15	0,44	0,83	39,08	0,00	7,19	1,99	0,00	-0,18	0,00	-0,01	2
86	FAA Ingeniería y Servicios Eléctricos	1,06	0,62	0,91	0,10	0,69	7,95	104,02	94,66	28,92	1,07	0,80	0,10	0,01	0,01	2
87	Queirolo M. S. A. Agencia de Aduanas	1,27	1,27	0,70	0,43	0,43	21,10	544,67	0,00	11,42	0,28	0,06	-0,31	-0,07	-0,32	2
88	Fortuna Internacional S. A.	0,01	0,00	69,35	-0,99	-0,01	0,99	4,76	32,35	0,00	0,58	16,22	0,23	-10,90	-27,02	2
89	Vale S. A.	0,65	0,52	1,58	-0,37	-0,24	-11,81	181,22	34,66	34,69	1,39	0,62	0,24	-0,07	-0,10	2
90	Fumiport S. A.	1,26	1,26	0,80	0,26	0,00	0,00	0,00	0,00	0,00	2,16	0,06	0,41	0,08	0,04	2
91	Braco S. R. L. Seguridad Industrial	0,26	0,26	2,47	-0,60	-1,13	-7,26	25,92	0,00	8,09	4,49	0,00	0,44	-0,45	-0,14	2
92	Protecto S. A.	0,71	0,31	1,39	-0,28	-0,86	-1,52	78,81	0,00	11,95	1,66	0,00	1,44	-0,40	-0,34	2
93	Clinica los Pinos S. A.	0,88	0,24	2,11	-0,53	4,48	0,80	23,25	0,00	2,27	0,91	0,28	1,26	-0,98	-1,54	2
94	Alerta Médica S. A.	0,25	0,20	1,96	-0,49	-0,24	-2,02	18,49	1,35	5,21	2,00	0,45	1,49	-1,00	-0,72	2

SECTOR

INDUSTRIA	1
COMERCIO Y SERVICIO	2
EXTRACION	3

ANEXO N° 02
INDICES (RAZONES) FINANCIERAS EMPRESAS SOLVENTES

N°	EMPRESA	Liquidez		Solvencia				Gestión				Rentabilidad			SECTOR	
		Raz Corr	Prub Acl	Raz End	Raz Pat	Ind Cap	Raz Cob AF	PPC	PIE	RAF	RAT	CV/V	ROE	ROA		RSV
1	FABRICA NACIONAL DE ACUMULADORES ETNA S.A	3,51	1,64	0,20	3,92	0,01	2,56	60,49	151,56	4,54	1,43	0,60	15,75	12,55	8,76	1
2	FABRICA PERUANA ETERNIT S.A	5,46	3,70	0,09	10,06	0,00	1,85	44,48	128,39	1,39	0,68	0,64	-1,68	-1,52	-2,24	1
3	FILAMENTOS INDUSTRIALES S.A	2,10	1,25	0,28	2,58	0,04	2,29	99,93	116,40	2,66	0,87	0,73	12,31	8,87	10,23	1
4	GLORIA S.A	1,00	0,49	0,55	0,82	0,40	2,05	55,83	81,55	1,75	0,64	0,77	7,45	3,36	5,27	1
5	INDUSTRIA TEXTIL PIURA S.A	2,10	1,25	0,28	2,58	0,04	2,29	99,93	116,40	2,66	0,87	0,73	12,31	8,87	10,23	1
6	INDECO S.A	1,56	0,69	0,29	2,45	0,07	1,26	61,40	96,92	1,28	0,78	0,86	-4,36	-3,10	-3,97	1
7	FIMA S.A	0,70	0,57	0,75	0,34	0,52	3,09	425,96	126,54	1,11	0,19	0,75	-10,84	-2,76	-14,62	1
8	INDUSTRIAS VENCEDOR S.A	1,46	0,82	0,33	2,05	0,01	1,56	66,55	95,90	2,64	1,15	0,66	9,51	6,40	5,58	1
9	LAPICES Y CONEXOS S.A. LAYCONSA	4,35	2,00	0,18	4,48	0,02	3,13	53,95	401,00	2,26	0,60	0,56	8,44	6,90	11,54	1
10	LIMA CAUCHO S.A	1,06	0,60	0,45	1,22	0,00	1,07	128,46	125,96	1,44	0,74	0,75	0,50	0,27	0,37	1
11	MANUFACTURA DE METALES Y ALUMINIO RECORD S.A	1,46	0,78	0,40	1,49	0,18	1,20	60,00	174,84	0,89	0,54	0,63	-1,95	-1,17	-2,18	1
12	CEMENTOS LIMA S.A.	1,32	0,35	0,45	1,24	0,32	1,10	5,37	251,74	0,60	0,45	0,38	18,60	10,28	23,00	1
13	MICHELL Y CIA. S.A	1,70	1,05	0,61	0,63	0,33	2,26	138,00	90,39	3,96	1,01	0,75	3,15	1,22	1,21	1
14	MOTORES DIESEL ANDINOS S.A	2,40	1,06	0,32	2,11	0,12	1,92	168,21	257,20	1,21	0,48	0,81	0,81	0,55	1,13	1
15	NEGOCIACION AGRICOLA VISTA ALEGRE S.A	0,64	0,28	0,84	0,19	0,68	0,72	0,00	152,50	0,60	0,42	1,00	-131,17	-20,69	-49,76	1
16	AGRO INDUSTRIAL PARAMONGA S.A.A.	0,65	0,31	0,60	0,66	0,47	0,98	11,58	108,54	0,31	0,24	0,83	-36,72	-14,63	-60,23	1
17	EMPRESA AGRARIA AZUCARERA ANDAHUASI S.A.A	1,91	0,27	0,16	5,29	0,01	1,24	11,51	252,19	0,34	0,23	0,81	1,38	1,16	5,03	1
18	CERVECERIA SAN JUAN S.A.	2,61	1,33	0,14	6,00	0,00	1,96	15,82	161,63	1,65	0,72	0,54	13,89	11,90	16,48	1
19	REACTIVOS NACIONALES S.A. RENASA	1,84	0,86	0,27	2,66	0,04	1,17	52,58	83,09	1,32	0,66	0,78	-8,75	-6,36	-7,43	1
20	SOCIEDAD INDUSTRIAL DE ARTICULOS DE METAL S.A.C	1,96	0,75	0,47	1,13	0,12	2,60	73,95	194,22	4,91	1,14	0,73	1,69	0,89	0,78	1
21	TEXTIL SAN CRISTOBAL S.A	2,41	1,97	0,77	0,30	0,49	1,21	423,65	130,49	0,87	0,33	0,69	5,71	1,33	4,06	1
22	YURA S.A	2,83	1,93	0,54	0,86	0,44	1,73	37,45	207,78	0,69	0,33	0,52	6,13	2,83	8,63	1
23	UNION DE CERVECERIAS PERUANAS BACKUS Y JOHNSTON S.A.A	1,63	1,05	0,28	2,61	0,10	2,21	51,07	230,72	1,04	0,38	0,42	10,77	7,79	20,58	1
24	SHOUGANG HIERRO PERU S.A.A	0,70	0,45	0,78	0,28	0,45	0,88	215,05	113,06	1,00	0,45	1,17	-17,68	-3,90	-8,69	1
25	Compañía Industrial Textil Credisa - Trutex S.A.A.	0,89	0,35	0,66	0,52	0,21	1,04	100,82	251,89	1,23	0,51	0,83	-15,15	-5,21	-10,15	1
26	COMPAÑIA UNIVERSAL TEXTIL S.A	1,23	0,36	0,29	2,44	0,09	1,05	55,12	205,93	0,60	0,45	0,69	4,08	2,89	6,46	1
27	CONSTRUCCIONES ELECTROMECHANICAS DELCROSA S.A	1,27	0,61	0,50	1,01	0,27	2,65	82,86	154,93	2,35	0,61	0,74	-2,88	-1,45	-2,38	1
28	CORPORACION ACEROS AREQUIPA S.A	1,97	0,98	0,41	1,45	0,06	1,25	34,40	113,64	1,52	0,77	0,87	-2,00	-1,18	-1,55	1
29	EXSA S.A	2,04	0,88	0,50	1,01	0,30	2,23	84,07	218,43	2,79	0,89	0,59	12,98	6,51	7,32	1
30	CONSORCIO INDUSTRIAL DE AREQUIPA S.A	3,32	1,54	0,33	2,06	0,18	2,38	37,28	127,31	3,87	1,34	0,63	20,37	13,72	10,26	1
31	CORPORACION CERAMICA S.A	3,33	1,41	0,19	4,34	0,00	2,19	84,57	153,70	2,75	1,02	0,77	-10,10	-8,21	-8,04	1
32	CORPORACION JOSE R. LINDLEY S.A	0,56	0,26	0,57	0,75	0,16	0,70	22,61	94,12	1,02	0,75	0,64	-59,81	-25,71	-34,40	1
33	AGROINDUSTRIAS SAN JACINTO S.A.A.	0,98	0,38	0,38	1,63	0,22	1,23	0,07	478,46	0,22	0,14	0,50	-0,10	-0,06	-0,44	1
34	EMPRESA AGROINDUSTRIAL LAREDO S.A.A	0,54	0,29	0,37	1,72	0,05	0,88	1,66	160,11	0,34	0,26	0,69	3,15	1,99	7,76	1
35	COMPAÑIA GOODYEAR DEL PERU S.A.	3,55	2,77	0,21	3,79	0,00	3,29	124,28	70,42	4,59	1,10	1,01	14,01	11,09	14,10	1
36	COMPAÑIA MINERA ATACCOCHA S.A.A.	0,65	0,37	0,24	3,10	0,04	0,98	47,70	52,68	0,67	0,53	0,65	5,45	4,12	7,71	3
37	COMPAÑIA MINERA MILPO S.A.A	1,62	1,45	0,35	1,83	0,20	1,88	36,38	53,22	0,84	0,38	0,66	2,45	1,58	4,42	3
38	COMPAÑIA MINERA RAURA S.A	1,90	1,30	0,27	2,66	0,07	1,56	32,96	40,55	2,23	1,12	0,77	-1,34	-0,98	-0,87	3
39	COMPAÑIA MINERA SAN IGNACIO DE MOROCOCHA S.A	1,18	0,64	0,29	2,41	0,05	1,30	34,67	80,34	1,58	0,90	0,44	5,19	3,67	4,07	3
40	COMPAÑIA MINERA SANTA LUISA S.A	1,80	1,12	0,33	2,04	0,05	1,50	11,02	56,70	3,03	1,42	0,73	19,54	13,11	9,21	3
41	EMPRESA AGRARIA CHIQUITOY S.A	0,47	0,04	0,32	2,17	0,06	0,84	22,27	458,85	0,09	0,07	1,21	-8,65	-5,92	-79,76	3
42	EMPRESA AGRICOLA BARRAZA S.A	1,12	0,21	0,20	3,98	0,11	1,04	0,00	187,18	0,28	0,25	0,74	-5,09	-4,07	-16,58	3
43	EMPRESA AGRICOLA GANADERA SALAMANCA S.A.A	1,31	0,21	0,05	19,27	0,00	1,04	0,33	121,81	0,19	0,18	0,83	-7,86	-7,48	-42,22	3
44	EMPRESA AGRICOLA SAN JUAN S.A	1,16	0,22	0,11	7,88	0,04	1,01	28,63	165,70	0,22	0,20	0,75	0,85	0,76	3,79	3
45	EMPRESA AGRICOLA SINTUCO S.A	0,95	0,04	0,31	2,26	0,11	0,91	5,19	201,66	0,22	0,19	1,11	5,21	3,61	19,28	3
46	ELECTRO ANDES S.. A.	3,02	3,00	0,45	0,82	0,40	0,92	59,37	35,14	0,34	0,37	0,33	9,32	5,14	31,16	2

SECTOR

INDUSTRIA	1
COMERCIO Y SERVICIO	2
EXTRACION	3

**ANEXO N° 02
INDICES (RAZONES) FINANCIERAS EMPRESAS SOLVENTES**

N°	EMPRESA	Liquidez		Solventia			Gestión					Rentabilidad			SECTOR	
		Raz Corr	Prub Acl	Raz End	Raz Pat	Ind Cap	Raz Cob AF	PPC	PIE	RAF	RAT	CVV	ROE	ROA		RSV
47	CONSORCIO TRANSMANTARO S.A	1,02	0,92	0,63	0,58	0,60	1,02	30,21	0,00	0,18	0,16	0,42	3,38	1,24	7,83	2
48	DUKE ENERGY EGENOR SOCIEDAD EN COMANDITA	4,01	3,12	0,18	4,55	0,15	1,08	62,81	57,23	0,14	0,13	0,58	2,34	1,92	15,32	2
49	EDEGEL S.A.A	0,59	0,52	0,28	2,63	0,15	0,99	75,44	312,45	0,11	0,10	0,08	5,02	3,63	37,49	2
50	EDELNOR S.A.A	0,83	0,67	0,37	1,67	0,21	0,94	67,95	23,83	0,51	0,43	0,75	8,36	5,23	12,05	2
51	ELECTRO SUR ESTE S.A.A	2,32	1,59	0,07	13,09	0,02	1,08	30,43	32,38	0,35	0,31	0,93	0,10	0,10	0,32	2
52	ELECTRO SUR MEDIO S.A.A.	2,35	2,09	0,20	4,03	0,11	1,20	75,28	16,58	0,62	0,46	0,78	1,16	0,93	2,01	2
53	EMPRESA EDITORA EL COMERCIO S.A	0,52	0,31	0,55	0,81	0,17	0,74	18,50	52,38	1,44	1,05	0,54	8,62	3,87	3,69	2
54	EMPRESA ELECTRICA DE PIURA S.A	3,18	2,84	0,31	2,23	0,23	1,38	30,47	4,32	0,89	0,58	0,95	0,30	0,21	0,36	2
55	EMPRESA REGIONAL DE SERVICIO PUBLICO DE ELECTRICIDAD D	2,18	1,79	0,09	10,58	0,04	1,08	51,76	25,51	0,19	0,17	1,03	-0,59	-0,54	-3,20	2
56	EMPRESA REGIONAL DE SERVICIO PUBLICO DE ELECTRICIDAD	0,71	0,42	0,15	5,86	0,05	1,05	34,44	29,02	0,33	0,29	0,96	0,04	0,04	0,13	2
57	SHOUGANG GENERACION ELECTRICA S.A.A	2,65	2,49	0,35	1,89	0,00	1,17	0,13	12,85	1,06	0,60	0,58	7,04	4,61	7,70	2
58	EMPRESA SIDERURGICA DEL PERU S.A.A. - SIDERPERU	0,92	0,46	0,34	1,95	0,09	1,03	59,00	139,05	0,47	0,33	0,78	-3,24	-2,14	-6,48	2
59	FERREYROS S.A.A	1,34	0,68	0,75	0,34	0,52	1,92	112,163	233,24	2,28	0,63	0,73	1,05	0,27	0,42	2
60	ALICORP S.A.A.	0,98	0,54	0,61	0,65	0,44	1,36	38,37	84,32	1,48	0,77	0,68	-9,77	-3,86	-5,04	2
61	AMERICA LEASING S.A.	1,04	1,02	0,83	0,20	0,71	103,31	807,72	0,00	24,26	0,14	0,41	18,99	3,19	23,50	2
62	AUSTRAL GROUP S.A.A.	0,34	0,24	0,88	0,13	0,69	0,49	84,30	83,61	0,40	0,30	1,71	-128,46	-15,15	-49,94	2
63	GRAÑA Y MONTERO S.A.A	4,29	4,18	0,13	6,84	0,08	524,39	0,00	0,00	7,88	0,01	0,00	3,51	3,06	215,16	2
64	HIDROSTAL S.A	3,76	1,56	0,19	4,37	0,03	2,14	75,88	211,77	2,37	0,93	0,63	4,17	3,39	3,65	2
65	INCA TOPS S.A.A	1,22	0,36	0,74	0,36	0,44	1,34	85,73	301,81	2,16	0,76	0,70	21,35	5,60	7,38	2
66	INMOBILIARIA MILENIA S.A	8,97	8,97	0,01	93,83	0,00	1,09	43,50	0,00	0,17	0,16	0,23	6,64	6,57	41,53	2
67	INTRÁDEVCO INDUSTRIAL S.A	1,97	0,93	0,38	1,60	0,15	1,54	54,45	177,15	1,31	0,61	0,69	11,48	7,07	11,53	2
68	INVERSIONES CENTENARIO S.A.A	2,35	0,94	0,65	0,54	0,27	0,91	154,56	1311,16	0,14	0,07	0,54	5,12	1,80	24,35	2
69	INVERSIONES EN TURISMO S.A. INVERTUR	0,19	0,07	0,42	1,36	0,22	0,79	10,36	230,79	0,25	0,23	0,15	-22,69	-13,05	-56,47	2
70	INVERSIONES NACIONALES DE TURISMO S.A. INTURSA	0,64	0,34	0,48	1,07	0,39	0,94	32,22	60,60	0,41	0,37	0,36	0,23	0,12	0,32	2
71	LUZ DEL SUR S.A.A	0,84	0,75	0,41	1,42	0,13	0,86	52,09	2,01	0,84	0,66	0,76	18,00	10,57	15,93	2
72	PROMOTORA CLUB EMPRESARIAL S.A	0,60	0,44	0,75	0,34	0,46	0,84	1991,98	0,00	0,07	0,04	0,00	-85,04	-21,53	-516,86	2
73	QUIMPAC S.A	0,84	0,49	0,60	0,66	0,32	1,16	46,10	97,76	1,29	0,65	0,71	4,71	1,88	2,90	2
74	RANSA COMERCIAL S.A	0,83	0,70	0,57	0,77	0,38	1,81	67,43	27,82	0,89	0,35	0,66	-3,76	-1,63	-4,73	2
75	NEGOCIOS E INMUEBLES S.A	6,21	5,90	0,02	41,20	0,00	26,38	140,50	99,54	1,05	0,04	0,69	1,90	1,86	47,94	2
76	PERU HOLDING DE TURISMO S.A.A	4,87	1,49	0,10	9,51	0,00	1598,86	99,40	1136,25	11,49	0,01	0,38	3,40	3,08	472,78	2
77	PERUBAR S.A	6,78	4,88	0,05	20,87	0,00	5,64	9,56	124,94	2,27	0,38	0,63	7,48	7,14	18,59	2
78	RED BICOLOR DE COMUNICACIONES S.A.A.	6,29	5,28	0,12	7,39	0,00	2,92	58,83	0,00	3,66	1,08	0,75	17,31	15,24	14,12	2
79	LP HOLDING S.A	0,86	0,21	0,44	1,25	0,36	839,95	41,50	246,83	82,83	0,09	1,24	1,21	0,67	7,89	2
80	LOS PORTALES S.A	2,66	0,43	0,80	0,24	0,70	4,24	160,694	1214,73	1,30	0,20	0,77	-49,09	-9,65	-48,65	2
81	ABB S.A.	1,59	1,07	0,63	0,58	0,06	4,58	82,05	53,35	19,68	1,67	0,92	0,49	0,18	0,11	2
82	SAGA FALABELLA S.A	0,84	0,11	0,64	0,57	0,27	0,87	1,19	84,81	3,33	1,90	0,76	14,19	5,15	2,71	2
83	SOCIEDAD INDUSTRIAL DE ARTICULOS DE METAL S.A.C	1,96	0,75	0,47	1,13	0,12	2,60	73,95	194,22	4,91	1,14	0,73	1,69	0,89	0,78	2
84	CONSORCIO AGUA AZUL S.A	0,50	0,49	0,70	0,43	0,62	393,75	72,87	10,51	55,33	0,11	0,21	9,69	2,89	26,30	2
85	TICINO DEL PERU S.A	9,29	7,38	0,09	10,01	0,00	6,18	29,35	110,00	7,02	1,03	0,53	19,04	17,31	16,76	2
86	SOUTHERN PERU COPPER CORPORATION	2,42	1,01	0,33	1,99	0,24	1,42	35,50	103,26	1,01	0,62	0,63	-1,72	-1,15	-1,85	2
87	TC SIGLO 21 S.A.A	0,52	0,51	0,33	2,05	0,00	0,79	185,36	0,00	0,14	0,12	1,95	-37,9131	-25,48	-215,13	2
88	TELEFONICA MOVILES S.A	0,34	0,25	0,63	0,59	0,01	0,69	105,38	30,80	0,66	0,36	0,58	-30,5978	-11,3879	-31,62	2
89	LOS PORTALES S.A	2,66	0,43	0,80	0,24	0,70	4,24	160,694	1214,73	1,30	0,20	0,77	-49,09	-9,65	-48,65	2
90	INDUSTRIAS DEL ENVASE S.A	1,00	0,32	0,41	1,43	0,15	1,13	36,12	115,43	1,23	0,75	0,77	5,41	3,19	4,26	2
91	INDUSTRIAS ELECTRO QUIMICAS S.A. IEQSA	1,03	0,62	0,60	0,66	0,44	1,01	64,46	56,59	1,14	0,80	0,84	2,69	1,07	1,34	2
92	METALURGICA PERUANA S.A	0,69	0,28	0,59	0,69	0,27	0,92	61,60	158,44	0,78	0,47	0,75	-6,36	-2,59	-5,49	2
93	BAYER S.A.	1,97	1,14	0,48	1,1	0,02	6,73	84,05	96,08	26,46	2,1	0,64	13,33	6,99	3,33	2
94	BRITISH AMERICAN TOBACCO DEL PERU HOLDINGS S.A.A.	2,34	1,53	0,41	1,43	0,12	2,97	162,38	130,5	4,19	0,94	0,72	5,37	3,16	3,35	2

SECTOR

INDUSTRIA	1
COMERCIO Y SERVICIO	2
EXTRACION	3

2.2. Estado de Ganancias y Pérdidas.

VENTAS

COSTO DE VENTAS

UTILIDAD BRUTA

GASTOS ADMINISTRATIVOS

GASTOS DE VENTAS

UTILIDAD (PÉRDIDA) DE OPERACIÓN

OTROS INGRESOS (EGRESOS)

INGRESOS DIVERSOS

CARGAS FINANCIERAS

INGRESOS FINANCIEROS

CARGAS EXCEPCIONALES

REI DEL EJERCICIO

RESULTADOS ANTES DE IMPUESTOS

IMPUESTO A LA RENTA

RESULTADO DEL EJERCICIO

ANEXO N° 04

ANOVA

		Suma de cuadrados	gl	Media cuadrática	F	Sig.
Raz Corr	Inter-grupos	73,289	1	73,289	36,649	0,000
	Intra-grupos	315,963	158	2,000		
	Total	389,252	159			
Prub Aci	Inter-grupos	32,195	1	32,195	22,304	0,000
	Intra-grupos	228,070	158	1,443		
	Total	260,265	159			
Raz End	Inter-grupos	310,895	1	310,895	31,426	0,000
	Intra-grupos	1563,096	158	9,893		
	Total	1873,990	159			
Raz Pat	Inter-grupos	932,570	1	932,570	13,776	0,000
	Intra-grupos	10695,819	158	67,695		
	Total	11628,389	159			
Ind Cap	Inter-grupos	80,102	1	80,102	1,251	0,265
	Intra-grupos	10114,147	158	64,014		
	Total	10194,249	159			
Raz Cob AF	Inter-grupos	90523,913	1	90523,913	3,365	0,068
	Intra-grupos	4249914,270	158	26898,192		
	Total	4340438,183	159			
PPC	Inter-grupos	1203,758	1	1203,758	0,019	0,889
	Intra-grupos	9820475,400	158	62154,908		
	Total	9821679,158	159			
PIE	Inter-grupos	13351,442	1	13351,442	0,051	0,821
	Intra-grupos	4,123E7	158	260965,445		
	Total	4,125E7	159			
RAF	Inter-grupos	20265,982	1	20265,982	13,628	0,000
	Intra-grupos	234962,165	158	1487,102		
	Total	255228,147	159			
RAT	Inter-grupos	114,597	1	114,597	15,354	0,000
	Intra-grupos	1179,246	158	7,464		
	Total	1293,843	159			
CVV	Inter-grupos	0,438	1	0,438	0,545	0,461
	Intra-grupos	126,885	158	0,803		
	Total	127,323	159			
ROE	Inter-grupos	34,200	1	34,200	0,074	0,786
	Intra-grupos	73038,860	158	462,271		
	Total	73073,060	159			
ROA	Inter-grupos	121,520	1	121,520	3,785	0,053
	Intra-grupos	5072,843	158	32,107		
	Total	5194,364	159			
RSV	Inter-grupos	222,171	1	222,171	0,056	0,813
	Intra-grupos	627616,803	158	3972,258		
	Total	627838,975	159			

**ANEXO N° 05
ESTADÍSTICOS POR EMPRESAS**

N°	Empresas	Grupo real	Grupo mayor				Segundo grupo mayor			Puntuaciones disclrimnantes	
			Grupo pronosticado	P(D>d G=g)		P(G=g D=d)	Distancia de Mahalanobis al cuadrado hasta	Grupo	P(G=g D=d)	Distancia de Mahalanobis al cuadrado hasta	Función 1
				p	gl						
1	Fabricaciones Metálicas Guevara S.A	0	1*	0,881	1	0,729	0,022	0	0,271	2,002	-0,633
2	Agroindustria Valle Verde S.A.	0	0	0,628	1	0,879	0,235	1	0,121	4,198	1,267
3	Industrias Canciller S.A.	0	0	0,700	1	0,651	0,148	1	0,349	1,391	0,397
4	Laboratorios Anakols S.A.	0	0	0,506	1	0,906	0,443	1	0,094	4,972	1,448
5	Laboratorios Famur S.A.	0	0	0,843	1	0,822	0,039	1	0,178	3,105	0,980
6	Industrial Altimira S.A.	0	1*	0,524	1	0,557	0,405	0	0,443	0,861	-0,146
7	Cía Químico Industrial Pintel S.A.	0	0	0,472	1	0,525	0,517	1	0,475	0,715	0,063
8	Sociedad Industrial Textil S.A.	0	1*	0,934	1	0,749	0,007	0	0,251	2,195	-0,699
9	Textiles del Sur S.A.	0	0	0,582	1	0,590	0,303	1	0,410	1,029	0,232
10	Curtiembre el Aguila S.A.	0	0	0,921	1	0,799	0,010	1	0,201	2,766	0,881
11	Fabrica de Tejidos La Unión S.A.	0	0	0,452	1	0,512	0,565	1	0,488	0,660	0,030
12	Servicios de Impresión S.A.	0	0	0,008	1	0,995	6,928	1	0,005	17,610	3,414
13	Kimide S. A.	0	1*	0,473	1	0,525	0,516	0	0,475	0,716	-0,064
14	Gráfica M & R S. A.	0	0	0,216	1	0,959	1,532	1	0,041	7,852	2,020
15	Plastisan S. A.	0	0	0,706	1	0,653	0,142	1	0,347	1,411	0,406
16	Cutiembre Cocodrilo S. A.	0	0	0,687	1	0,644	0,162	1	0,356	1,349	0,379
17	Compañía Embotelladora Huánuco S. A.	0	0	0,755	1	0,676	0,098	1	0,324	1,567	0,470
18	Ladrillera Jesús S. A.	0	0	0,093	1	0,979	2,822	1	0,021	10,525	2,462
19	Mosaicos Pomabamba S. A.	0	1*	0,465	1	0,520	0,534	0	0,480	0,695	-0,052
20	Industrialización de Alimentos S. A. (INDALSA)	0	0	0,527	1	0,558	0,400	1	0,442	0,869	0,150
21	Industrias Precisión S. A.	0	0	0,615	1	0,607	0,253	1	0,393	1,126	0,279
22	Food Process S. A.	0	0	0,595	1	0,597	0,283	1	0,403	1,066	0,250
23	Papeles Industriales S. A.	0	0	0,170	1	0,967	1,885	1	0,033	8,628	2,155
24	Polímeros y Adhesivos S. A. (POLYANSA)	0	0	0,003	1	0,997	8,957	1	0,003	20,768	3,775
25	Poli San S. R. Ltda.	0	0	0,481	1	0,530	0,496	1	0,470	0,740	0,078
26	B. B. Plast S. A.	0	0	0,621	1	0,610	0,245	1	0,390	1,144	0,287
27	Cotton Export S. A.	0	0	0,865	1	0,723	0,029	1	0,277	1,945	0,613
28	Tejidos Evy Land S. R. L.	0	0	0,338	1	0,938	0,919	1	0,062	6,367	1,741
29	Fabrica de Material Didáctico S. A.	0	0	0,128	1	0,974	2,315	1	0,026	9,524	2,304
30	Productos Alimenticios PGPR S. R. L.	0	0	0,801	1	0,696	0,064	1	0,304	1,721	0,530
31	Textiles Generales S. A.	0	0	0,535	1	0,563	0,386	1	0,437	0,890	0,161
32	Amicro S. A. (APPLE PERU)	0	0	0,450	1	0,511	0,570	1	0,489	0,655	0,027
33	Cesar A. Peirano S. A.	0	0	0,417	1	0,924	0,659	1	0,076	5,645	1,594
34	Oechsle Cía. Comercial S. A.	0	0	0,989	1	0,769	0,000	1	0,231	2,403	0,768
35	Sociedad Andina Grandes Almacenes S. A. (SAGA)	0	0	0,701	1	0,651	0,148	1	0,349	1,392	0,398
36	Los Pucci S. A.	0	1*	0,841	1	0,713	0,040	0	0,287	1,859	-0,581
37	Industriales Caltex S. A.	0	0	0,574	1	0,585	0,316	1	0,415	1,005	0,220
38	Exportaciones Larhard S. A.	0	0	0,285	1	0,948	1,143	1	0,052	6,936	1,851
39	Comercial de Soldadura Industriales S. A.	0	1*	0,653	1	0,627	0,203	0	0,373	1,242	-0,332
40	Record Multimotriz S. A.	0	1*	0,476	1	0,527	0,508	0	0,473	0,725	-0,069

41	Casa Crevani S. A.	0	0	0,759	1	0,678	0,094	1	0,322	1,581	0,475
42	Old Wood S. A. C.	0	0	0,805	1	0,698	0,061	1	0,302	1,736	0,535
43	Agricultura para la Exportación E.I.R.L (AGREX)	0	0	0,516	1	0,904	0,423	1	0,096	4,905	1,432
44	Comercial Centeno S. A.	0	1*	0,533	1	0,561	0,390	0	0,439	0,884	-0,158
45	Hogar S. A.	0	0	0,435	1	0,500	0,610	1	0,500	0,614	0,001
46	Electrónica Latinoamerica S. A. C. (ELECTROL)	0	0	0,460	1	0,915	0,545	1	0,085	5,302	1,520
47	Alpigol S. A.	0	0	0,731	1	0,665	0,118	1	0,335	1,489	0,438
48	Karma Plastic S. A.	0	0	0,619	1	0,610	0,247	1	0,390	1,140	0,286
49	Colonial Plastic S. A.	0	0	0,450	1	0,917	0,572	1	0,083	5,385	1,538
50	Distribuidora Marca S. A. (DISMARCA)	0	0	0,031	1	0,990	4,675	1	0,010	13,887	2,944
51	Jeawel S. A.	0	0	0,146	1	0,971	2,112	1	0,029	9,107	2,236
52	Minol Perú Corporation S. A.	0	0	0,454	1	0,513	0,560	1	0,487	0,666	0,034
53	Despachos Internacionales Pacífico S. A.	0	0	0,630	1	0,615	0,232	1	0,385	1,173	0,301
54	Empresa de Transporte Velásquez S. A.	0	0	0,687	1	0,644	0,162	1	0,356	1,349	0,379
55	Empresa de Transporte Unidos de Centro S. A. (ETUC)	0	0	0,755	1	0,847	0,098	1	0,153	3,523	1,095
56	Japan Tuna del Perú S. A. Agentes Marítimos	0	1*	0,461	1	0,518	0,542	0	0,482	0,686	-0,046
57	Empresa de Transporte Expreso Moderno E.I.R.L	0	0	0,516	1	0,551	0,423	1	0,449	0,836	0,132
58	GMC Ingenieros S. A.	0	0	0,444	1	0,507	0,585	1	0,493	0,640	0,018
59	Velca S.A.C.	0	0	0,537	1	0,899	0,381	1	0,101	4,761	1,400
60	INSASA Contratista Generales S.A.C:	0	0	0,915	1	0,801	0,011	1	0,199	2,793	0,889
61	Atlantic Unión S. A.	0	0	0,696	1	0,649	0,152	1	0,351	1,378	0,392
62	Agentes Aduaneros Universal S. A. (AGADUSA)	0	0	0,694	1	0,863	0,155	1	0,137	3,832	1,175
63	Servicios de Personalización Magnetica S. A.	0	0	0,659	1	0,630	0,195	1	0,370	1,261	0,341
64	Horizontes S. A. Asesoría y Servicios Empresariales	0	0	0,012	1	0,994	6,367	1	0,006	16,709	3,305
65	Hotel Perú S. A:	0	0	0,862	1	0,817	0,030	1	0,183	3,021	0,956
66	F & F Publicidad S. A.	0	0	0,044	1	0,988	4,061	1	0,012	12,813	2,797
67	Industrias Texoro S. A. (INDUTEX)	0	0	0,127	1	0,974	2,324	1	0,026	9,542	2,307
68	Inversiones Mira S. A.	0	0	0,682	1	0,642	0,168	1	0,358	1,334	0,373
69	Cooperativa de Trabajo y Fomento de Empleo Atlas Ltd	0	0	0,075	1	0,982	3,171	1	0,018	11,190	2,563
70	Cia. Servicios Integral S. A.	0	0	0,448	1	0,509	0,575	1	0,491	0,650	0,024
71	FAA Ingeniería y Servicios Eléctricos	0	0	0,532	1	0,561	0,391	1	0,439	0,882	0,157
72	Queirolo M. S. A. Agencia de Aduanas	0	0	0,662	1	0,632	0,191	1	0,368	1,271	0,345
73	Agropecuaria Pilar S. A.	0	1	0,392	1	0,929	0,734	0	0,071	5,862	-1,639
74	Avícola Rosmar S. A.	0	0	0,007	1	0,996	7,173	1	0,004	18,000	3,460
75	Del Agro Export Corp S. A.	0	0	0,590	1	0,594	0,290	1	0,406	1,053	0,244
76	Agro Guayabito S. A.	0	0	0,477	1	0,528	0,506	1	0,472	0,728	0,071
77	Tramsa Agro S. A.	0	1*	0,144	1	0,971	2,130	0	0,029	9,143	-2,242
78	Compañía Minera Atalaya S. A.	0	1*	0,685	1	0,643	0,164	0	0,357	1,344	-0,377
79	Compañía Minera Metalúrgica Huancayo S. A.	0	0	0,809	1	0,700	0,058	1	0,300	1,750	0,541
80	Urin Cañ S. R. L.	0	0	0,013	1	0,994	6,235	1	0,006	16,494	3,279

81	FABRICA NACIONAL DE ACUMULADORES ETNA S.A	1	1	0,320	1	0,942	0,990	0	0,058	6,550	-1,777
82	FABRICA PERUANA ETERNIT S.A	1	1	0,133	1	0,973	2,262	0	0,027	9,414	-2,286
83	FILAMENTOS INDUSTRIALES S.A	1	1	0,992	1	0,770	0,000	0	0,230	2,415	-0,772
84	GLORIA S.A	1	1	0,594	1	0,596	0,284	0	0,404	1,065	-0,250
85	INDUSTRIA TEXTIL PIURA S.A	1	1	0,992	1	0,770	0,000	0	0,230	2,415	-0,772
86	INDECO S.A	1	1	0,870	1	0,725	0,027	0	0,275	1,962	-0,619
87	FIMA S.A	1	0*	0,608	1	0,604	0,264	1	0,396	1,104	0,269
88	INDUSTRIAS VENCEDOR S.A	1	1	0,763	1	0,679	0,091	0	0,321	1,594	-0,480
89	LAPICES Y CONEXOS S.A. LAYCONSA	1	1	0,145	1	0,971	2,120	0	0,029	9,122	-2,238
90	LIMA CAUCHO S.A	1	1	0,549	1	0,571	0,359	0	0,429	0,932	-0,183
91	MANUFACTURA DE METALES Y ALUMINIO RECORD S.A	1	1	0,777	1	0,686	0,080	0	0,314	1,643	-0,500
92	CEMENTOS LIMA S.A.	1	1	0,916	1	0,743	0,011	0	0,257	2,130	-0,677
93	MICHELL Y CIA. S.A	1	1	0,668	1	0,635	0,184	0	0,365	1,289	-0,353
94	MOTORES DIESEL ANDINOS S.A	1	1	0,819	1	0,829	0,052	0	0,171	3,215	-1,011
95	NEGOCIACION AGRICOLA VISTA ALEGRE S.A	1	1	0,710	1	0,655	0,138	0	0,345	1,423	-0,411
96	AGRO INDUSTRIAL PARAMONGA S.A.A.	1	1	0,695	1	0,648	0,154	0	0,352	1,374	-0,390
97	EMPRESA AGRARIA AZUCARERA ANDAHUASI S.A.A	1	1	0,587	1	0,888	0,295	0	0,112	4,443	-1,326
98	CERVECERIA SAN JUAN S.A.	1	1	0,568	1	0,892	0,325	0	0,108	4,557	-1,353
99	REACTIVOS NACIONALES S.A. RENASA	1	1	0,969	1	0,762	0,001	0	0,238	2,329	-0,744
100	SOCIEDAD INDUSTRIAL DE ARTICULOS DE METAL S.A.C	1	1	0,982	1	0,779	0,000	0	0,221	2,517	-0,804
101	TEXTIL SAN CRISTOBAL S.A	1	1	0,557	1	0,576	0,345	0	0,424	0,954	-0,195
102	YURA S.A	1	1	0,880	1	0,811	0,023	0	0,189	2,942	-0,933
103	UNION DE CERVECERIAS PERUANAS BACKUS Y JOHNST	1	1	0,804	1	0,698	0,062	0	0,302	1,732	-0,534
104	SHOUGANG HIERRO PERU S.A.A	1	0*	0,529	1	0,559	0,397	1	0,441	0,873	0,152
105	Compañía Industrial Textil Credisa - Trutex S.A.A.	1	1	0,547	1	0,570	0,362	0	0,430	0,927	-0,180
106	COMPAÑIA UNIVERSAL TEXTIL S.A	1	1	0,854	1	0,718	0,034	0	0,282	1,904	-0,598
107	CONSTRUCCIONES ELECTROMECANICAS DELCROSA S.	1	1	0,682	1	0,642	0,167	0	0,358	1,335	-0,373
108	CORPORACION ACEROS AREQUIPA S.A	1	1	0,993	1	0,770	0,000	0	0,230	2,422	-0,774
109	EXSA S.A	1	1	0,946	1	0,791	0,005	0	0,209	2,662	-0,849
110	CONSORCIO INDUSTRIAL DE AREQUIPA S.A	1	1	0,383	1	0,930	0,760	0	0,070	5,934	-1,654
111	COMPAÑIA MINERA ATACOCOA S.A.A.	1	1	0,546	1	0,570	0,364	0	0,430	0,924	-0,179
112	COMPAÑIA MINERA MILPO S.A.A	1	1	0,626	1	0,613	0,238	0	0,387	1,160	-0,295
113	COMPAÑIA MINERA RAURA S.A	1	1	0,817	1	0,703	0,053	0	0,297	1,778	-0,551
114	COMPAÑIA MINERA SAN IGNACIO DE MOROCOCHA S.A	1	1	0,727	1	0,663	0,122	0	0,337	1,476	-0,433
115	COMPAÑIA MINERA SANTA LUISA S.A	1	1	0,904	1	0,738	0,015	0	0,262	2,085	-0,662
116	EMPRESA AGRARIA CHIQUITOY S.A	1	1	0,862	1	0,721	0,030	0	0,279	1,932	-0,608
117	EMPRESA AGRICOLA BARRAZA S.A	1	1	0,996	1	0,771	0,000	0	0,229	2,430	-0,777
118	EMPRESA AGRICOLA GANADERA SALAMANCA S.A.A	1	1	0,519	1	0,903	0,415	0	0,097	4,879	-1,427
119	ELECTRO ANDES S.. A.	1	1	0,675	1	0,638	0,176	0	0,362	1,311	-0,363
120	CONSORCIO TRANSMANTARO S.A	1	1	0,484	1	0,532	0,489	0	0,468	0,748	-0,083

121	DUKE ENERGY EGENOR SOCIEDAD EN COMANDITA	1	1	0,605	1	0,884	0,267	0	0,116	4,332	-1,299
122	EDEGEL S.A.A	1	0*	0,531	1	0,560	0,393	1	0,440	0,878	0,155
123	EDELNOR S.A.A	1	1	0,470	1	0,523	0,522	0	0,477	0,709	-0,060
124	ELECTRO SUR ESTE S.A.A	1	1	0,768	1	0,844	0,087	0	0,156	3,456	-1,077
125	ELECTRO SUR MEDIO S.A.A.	1	1	0,813	1	0,702	0,056	0	0,298	1,765	-0,546
126	EMPRESA EDITORA EL COMERCIO S.A	1	0*	0,435	1	0,500	0,611	1	0,500	0,613	0,001
127	EMPRESA ELECTRICA DE PIURA S.A	1	1	0,959	1	0,758	0,003	0	0,242	2,289	-0,731
128	EMPRESA REGIONAL DE SERVICIO PUBLICO DE ELECTR	1	1	0,997	1	0,774	0,000	0	0,226	2,460	-0,786
129	EMPRESA REGIONAL DE SERVICIO PUBLICO DE ELECTR	1	1	0,609	1	0,605	0,261	0	0,395	1,110	-0,271
130	SHOUGANG GENERACION ELECTRICA S.A.A	1	1	0,828	1	0,708	0,047	0	0,292	1,814	-0,565
131	EMPRESA SIDERURGICA DEL PERU S.A.A. - SIDERPERU	1	1	0,626	1	0,613	0,238	0	0,387	1,159	-0,294
132	FERREYROS S.A.A	1	1	0,628	1	0,614	0,235	0	0,386	1,166	-0,298
133	ALICORP S.A.A.	1	1	0,558	1	0,576	0,344	0	0,424	0,957	-0,196
134	AMERICA LEASING S.A.	1	0*	0,995	1	0,774	0,000	1	0,226	2,466	0,788
135	AUSTRAL GROUP S.A.A.	1	1	0,523	1	0,556	0,409	0	0,444	0,856	-0,143
136	GRAÑA Y MONTERO S.A.A	1	1	0,782	1	0,688	0,077	0	0,312	1,658	-0,505
137	HIDROSTAL S.A	1	1	0,230	1	0,957	1,438	0	0,043	7,638	-1,982
138	INCA TOPS S.A.A	1	1	0,692	1	0,646	0,157	0	0,354	1,363	-0,385
139	INMOBILIARIA MILENIA S.A	1	1	0,002	1	0,997	9,225	0	0,003	21,175	-3,819
140	INTRADEVCO INDUSTRIAL S.A	1	1	0,956	1	0,787	0,003	0	0,213	2,622	-0,837
141	INVERSIONES CENTENARIO S.A.A	1	1	0,931	1	0,748	0,008	0	0,252	2,184	-0,696
142	INVERSIONES EN TURISMO S.A. INVERTUR	1	1	0,572	1	0,584	0,319	0	0,416	0,999	-0,217
143	INVERSIONES NACIONALES DE TURISMO S.A. INTURSA	1	1	0,533	1	0,562	0,389	0	0,438	0,884	-0,158
144	LUZ DEL SUR S.A.A	1	1	0,461	1	0,517	0,544	0	0,483	0,684	-0,045
145	PROMOTORA CLUB EMPRESARIAL S.A	1	1	0,208	1	0,961	1,583	0	0,039	7,966	-2,040
146	QUIMPAC S.A	1	1	0,504	1	0,544	0,447	0	0,456	0,803	-0,114
147	RANSA COMERCIAL S.A	1	1	0,461	1	0,518	0,543	0	0,482	0,684	-0,045
148	NEGOCIOS E INMUEBLES S.A	1	1	0,224	1	0,958	1,480	0	0,042	7,735	-1,999
149	PERU HOLDING DE TURISMO S.A.A	1	1	0,179	1	0,965	1,810	0	0,035	8,466	-2,127
150	PERUBAR S.A	1	1	0,030	1	0,990	4,725	0	0,010	13,973	-2,956
151	RED BICOLOR DE COMUNICACIONES S.A.A.	1	1	0,207	1	0,961	1,589	0	0,039	7,981	-2,043
152	LP HOLDING S.A	1	1	0,810	1	0,832	0,058	0	0,168	3,256	-1,022
153	LOS PORTALES S.A	1	1	0,370	1	0,932	0,802	0	0,068	6,052	-1,678
154	ABB S.A.	1	1	0,487	1	0,534	0,482	0	0,466	0,757	-0,088
155	SAGA FALABELLA S.A	1	1	0,601	1	0,600	0,273	0	0,400	1,086	-0,260
156	SOCIEDAD INDUSTRIAL DE ARTICULOS DE METAL S.A.C	1	1	0,982	1	0,779	0,000	0	0,221	2,517	-0,804
157	CONSORCIO AGUA AZUL S.A	1	0*	0,443	1	0,506	0,588	1	0,494	0,637	0,016
158	TIGINO DEL PERU S.A	1	1	0,010	1	0,995	6,613	0	0,005	17,105	-3,354
159	SOUTHERN PERU COPPER CORPORATION	1	1	0,676	1	0,867	0,175	0	0,133	3,930	-1,200
160	TC SIGLO 21 S.A.A	1	1	0,902	1	0,805	0,015	0	0,195	2,847	-0,905

* Empresa mal clasificada

ANEXO N° 06
CLASIFICACION DE LAS 28 EMPRESAS PARA LA VALIDACION

N°	EMPRESA	Liquidez		Solvencia			Gestión					Rentabilidad			COND	SECTOR	FCL1	FCL2	GRUPO PRONOSTICADO	
		Raz Corr	Prub Acl	Raz End	Raz Pat	Ind Cap	Raz Cob AF	PPC	PIE	RAF	RAT	CVV	ROE	ROA						RSV
1	Cobres Laminados S. A. (COBELSA)	0,45	0,34	0,95	0,06	0,56	0,21	46,23	37,69	1,25	0,75	0,80	-4,54	-0,17	-0,33	0	1	-0,710	-1,002	0
2	Cartones Nacionales S. A. (CARTONSA)	0,07	0,00	0,95	0,06	0,92	1,02	0,00	0,00	0,00	0,00	0,00	-4,10	-0,15	0,00	0	1	-2,318	-2,417	0
3	Procesadora Yancay S. R. Ltda.	0,00	0,00	1,75	-0,43	-0,01	-0,75	0,00	0,00	0,02	0,02	0,85	0,00	0,00	-0,10	0	1	-1,065	-1,634	0
4	Industria Selva S. A. (INDULSEL)	0,41	0,26	1,16	-0,32	-0,12	-1,64	104,49	213,20	1,86	0,47	0,76	0,78	-0,25	-0,76	0	1	-0,407	-0,953	0
5	Industrias de Granos Alimenticios S. A. C. (IGASAC)	0,81	0,56	0,92	0,09	0,49	0,49	33,35	46,62	4,98	1,58	0,84	-1,09	-0,06	-0,06	0	1	-0,162	-0,386	0
6	Fortuna Internacional S. A.	0,01	0,00	69,35	-0,99	-0,01	0,99	4,76	32,35	0,00	0,58	16,22	0,23	-10,90	-27,02	0	2	45,523	26,441	0
7	Vale S. A.	0,65	0,52	1,58	-0,37	-0,24	-11,81	181,22	34,66	34,69	1,39	0,62	0,24	-0,07	-0,10	0	2	0,472	-0,580	0
8	Fumiport S. A.	1,26	1,26	0,80	0,26	0,00	0,00	0,00	0,00	2,16	0,06	0,41	0,08	0,04	0	2	-0,964	-1,037	0	
9	Braco S. R. L. Seguridad Industrial	0,26	0,26	2,47	-0,60	-1,13	-7,26	25,92	0,00	8,09	4,49	0,00	0,44	-0,45	-0,14	0	2	-0,227	-1,586	0
10	Protecto S. A.	0,71	0,31	1,39	-0,28	-0,86	-1,52	78,81	0,00	11,95	1,66	0,00	1,44	-0,40	-0,34	0	2	-0,776	-0,979	0
11	Clinica los Pinos S. A.	0,88	0,24	2,11	-0,53	4,48	0,80	23,25	0,00	2,27	0,91	0,28	1,26	-0,98	-1,54	0	2	-0,310	-0,175	†*
12	Alerta Médica S. A.	0,25	0,20	1,96	-0,49	-0,24	-2,02	18,49	1,35	5,21	2,00	0,45	1,49	-1,00	-0,72	0	2	-0,581	-1,425	0
13	Pesquera Trece S. A.	0,76	0,76	1,08	-0,08	0,00	-0,46	11,89	0,00	0,70	0,12	0,71	0,40	-0,02	-0,27	0	3	-0,907	-1,051	0
14	Gerencia y Representaciones Pesqueras S. A. (GERPESA)	0,51	0,12	1,11	-0,10	2,73	0,12	51,84	67,34	0,91	0,48	0,76	2,13	-0,16	-0,49	0	3	-0,570	-0,641	0
15	CORPORACION CERAMICA S.A	3,33	1,41	0,19	4,34	0,00	2,19	64,57	153,70	2,75	1,02	0,77	-10,10	-8,21	-8,04	1	1	1,978	4,430	1
16	CORPORACION JOSE R. LINDLEY S.A	0,56	0,26	0,57	0,75	0,16	0,70	22,61	94,12	1,02	0,75	0,64	-59,81	-25,71	-34,40	1	1	0,255	0,186	0*
17	AGROINDUSTRIAS SAN JACINTO S.A.A.	0,98	0,38	0,38	1,63	0,22	1,23	0,07	478,46	0,22	0,14	0,50	-0,10	-0,06	-0,44	1	1	-0,738	-0,438	1
18	EMPRESA AGROINDUSTRIAL LAREDO S.A.A	0,54	0,29	0,37	1,72	0,05	0,88	1,66	160,11	0,34	0,26	0,69	3,15	1,99	7,76	1	1	-1,302	-1,260	1
19	COMPANIA GOODYEAR DEL PERU S.A.	3,55	2,77	0,21	3,79	0,00	3,29	124,28	70,42	4,59	1,10	1,01	14,01	11,09	14,10	1	1	1,343	2,928	1
20	EMPRESA AGRICOLA SAN JUAN S.A	1,16	0,22	0,11	7,88	0,04	1,01	28,63	165,70	0,22	0,20	0,75	0,85	0,76	3,79	1	3	-0,898	0,273	1
21	EMPRESA AGRICOLA SINTUCO S.A	0,95	0,04	0,31	2,26	0,11	0,91	5,19	201,66	0,22	0,19	1,11	5,21	3,61	19,28	1	3	-0,336	0,304	1
22	TELEFONICA MOVILES S.A	0,34	0,25	0,63	0,59	0,01	0,69	105,38	30,80	0,66	0,36	0,58	-30,60	-11,39	-31,62	1	2	-0,736	-0,798	0*
23	CEMA COMUNICACIONES S. A.	4,44	2,44	0,06	0,84	0,18	0,99	80,00	35,00	4,90	0,80	0,65	0,25	0,12	3,30	1	2	2,340	5,362	1
24	INDUSTRIAS DEL ENVASE S.A	1,00	0,32	0,41	1,43	0,15	1,13	36,12	115,43	1,23	0,75	0,77	5,41	3,19	4,26	1	2	-0,600	-0,047	1
25	INDUSTRIAS ELECTRO QUIMICAS S.A. IEQSA	1,03	0,62	0,60	0,66	0,44	1,01	64,46	56,59	1,14	0,80	0,84	2,69	1,07	1,34	1	2	-0,329	-0,098	1
26	METALURGICA PERUANA S.A	0,69	0,28	0,59	0,69	0,27	0,92	61,60	158,44	0,78	0,47	0,75	-6,36	-2,59	-5,49	1	2	-0,507	-0,399	1
27	BAYER S. A.	1,97	1,14	0,48	1,1	0,02	6,73	84,05	96,08	26,46	2,1	0,64	13,33	6,99	3,33	1	2	0,585	1,152	1
28	BRITISH AMERICAN TOBACCO DEL PERU HOLDINGS S.A.A.	2,34	1,53	0,41	1,43	0,12	2,97	162,38	130,5	4,19	0,94	0,72	5,37	3,16	3,35	1	2	0,827	1,793	1

* Empresa mal clasificadas

FCL : Función de Clasificación Lineal

ANEXO N° 07
ESTADÍSTICOS POR EMPRESAS (UTILIANDO TRES RATIOS)

N°	Empresas	Grupo real	Grupo mayor					Segundo grupo mayor			Puntuaciones discriminantes
			Grupo pronosticado	P(D>d G=g)		P(G=g D=d)	Distancia de Mahalanobis al cuadrado hasta	Grupo	P(G=g D=d)	Distancia de Mahalanobis al cuadrado	Función 1
				p	gl						
1	Fabricaciones Metálicas Guevara S.A	0	0	0,735	1	0,809	0,115	1	0,191	2,996	1,035
2	Agroindustria Valle Verde S.A.	0	0	0,929	1	0,699	0,008	1	0,301	1,696	0,607
3	Industrias Canciller S.A.	0	0	0,553	1	0,536	0,352	1	0,464	0,638	0,103
4	Laboratorios Anako S S.A.	0	0	0,258	1	0,927	1,282	1	0,073	6,370	1,828
5	Laboratorios Famur S.A.	0	0	0,963	1	0,712	0,002	1	0,288	1,809	0,649
6	Industrial Altimira S.A.	0	1*	0,586	1	0,553	0,296	0	0,447	0,718	-0,152
7	Cía Químico Industrial Pintel S.A.	0	0	0,693	1	0,603	0,156	1	0,397	0,994	0,301
8	Sociedad Industrial Textil S.A.	0	1*	0,978	1	0,732	0,001	0	0,268	2,015	-0,724
9	Textiles del Sur S.A.	0	0	0,625	1	0,572	0,239	1	0,428	0,816	0,207
10	Curtiembre el Aguila S.A.	0	0	0,911	1	0,755	0,012	1	0,245	2,260	0,807
11	Fabrica de Tejidos La Unión S.A.	0	0	0,503	1	0,509	0,450	1	0,491	0,520	0,025
12	Servicios de Impresión S.A.	0	0	0,000	1	0,997	12,680	1	0,003	24,529	4,257
13	Kimide S. A.	0	1*	0,540	1	0,529	0,375	0	0,471	0,607	-0,083
14	Gráfica M & R S. A.	0	0	0,271	1	0,924	1,212	1	0,076	6,213	1,797
15	Plastisan S. A.	0	1*	0,525	1	0,521	0,404	0	0,479	0,571	-0,060
16	Curtiembre Cocodrilo S. A.	0	0	0,654	1	0,586	0,200	1	0,414	0,891	0,248
17	Compañía Embotelladora Huánuco S. A.	0	0	0,818	1	0,657	0,053	1	0,343	1,349	0,466
18	Ladrillera Jesús S. A.	0	0	0,164	1	0,948	1,938	1	0,052	7,750	2,088
19	Mosaicos Pomabamba S. A.	0	0	0,527	1	0,522	0,401	1	0,478	0,575	0,063
20	Industrialización de Alimentos S. A. (INDALSA)	0	0	0,617	1	0,568	0,250	1	0,432	0,795	0,196
21	Industrias Precisión S. A.	0	0	0,636	1	0,577	0,224	1	0,423	0,844	0,223
22	Food Process S. A.	0	0	0,610	1	0,564	0,260	1	0,436	0,778	0,186
23	Papeles Industriales S. A.	0	0	0,224	1	0,935	1,477	1	0,065	6,798	1,911
24	Polímeros y Adhesivos S. A. (POLYANSA)	0	0	0,000	1	0,997	12,431	1	0,003	24,183	4,222
25	Poli San S. R. Ltda.	0	0	0,519	1	0,518	0,417	1	0,482	0,557	0,050
26	B. B. Plast S. A.	0	0	0,653	1	0,585	0,202	1	0,415	0,887	0,246
27	Cotton Export S. A.	0	0	0,888	1	0,684	0,020	1	0,316	1,565	0,555
28	Tejidos Evy Land S. R. L.	0	0	0,856	1	0,772	0,033	1	0,228	2,476	0,878
29	Fabrica de Material Didáctico S. A.	0	0	0,015	1	0,987	5,909	1	0,013	14,613	3,127
30	Productos Alimenticios PGPR S. R. L.	0	0	0,875	1	0,679	0,025	1	0,321	1,524	0,539
31	Textiles Generales S. A.	0	1*	0,531	1	0,524	0,393	0	0,476	0,586	-0,069
32	Amicro S. A. (APPLE PERU)	0	1*	0,512	1	0,514	0,429	0	0,486	0,543	-0,041
33	Cesar A. Peirano S. A.	0	0	0,890	1	0,762	0,019	1	0,238	2,341	0,834
34	Oechsle Cía. Comercial S. A.	0	0	0,879	1	0,765	0,023	1	0,235	2,385	0,849
35	Sociedad Andina Grandes Almacenes S. A. (SAGA)	0	0	0,684	1	0,599	0,166	1	0,401	0,969	0,288
36	Los Pucci S. A.	0	1*	0,859	1	0,673	0,032	0	0,327	1,473	-0,518
37	Industriales Caltex S. A.	0	0	0,715	1	0,613	0,133	1	0,387	1,054	0,331
38	Exportaciones Larhard S. A.	0	0	0,117	1	0,959	2,456	1	0,041	8,754	2,263
39	Comercial de Soldadura Industriales S. A.	0	0	0,548	1	0,533	0,361	1	0,467	0,625	0,095
40	Record Multimotriz S. A.	0	0	0,502	1	0,509	0,450	1	0,491	0,520	0,025

41	Casa Crevani S. A.	0	0	0,752	1	0,629	0,100	1	0,371	1,156	0,379
42	Old Wood S. A. C.	0	0	0,896	1	0,687	0,017	1	0,313	1,589	0,565
43	Agricultura para la Exportación E.I.R.L (AGREX)	0	1*	0,493	1	0,503	0,471	0	0,497	0,498	-0,010
44	Comercial Centeno S. A.	0	1*	0,531	1	0,524	0,393	0	0,476	0,585	-0,069
45	Hogar S. A.	0	0	0,496	1	0,505	0,463	1	0,495	0,506	0,015
46	Electrónica Latinoamerica S. A. C. (ELECTROL)	0	0	0,848	1	0,668	0,037	1	0,332	1,440	0,504
47	Alpígol S. A.	0	0	0,492	1	0,503	0,472	1	0,497	0,496	0,009
48	Karma Plastic S. A.	0	0	0,786	1	0,643	0,074	1	0,357	1,254	0,424
49	Colonial Plastic S. A.	0	0	0,481	1	0,875	0,497	1	0,125	4,396	1,401
50	Distribuidora Marca S. A. (DISMARCA)	0	0	0,042	1	0,978	4,121	1	0,022	11,709	2,726
51	Jeawel S. A.	0	0	0,240	1	0,931	1,378	1	0,069	6,583	1,870
52	Minol Perú Corporation S. A.	0	1*	0,515	1	0,516	0,424	0	0,484	0,549	-0,045
53	Despachos Internacionales Pacífico S. A.	0	0	0,595	1	0,557	0,283	1	0,443	0,739	0,164
54	Empresa de Transporte Velásquez S. A.	0	0	0,657	1	0,587	0,197	1	0,413	0,899	0,252
55	Empresa de Transporte Unidos de Centro S. A. (ETUC)	0	0	0,278	1	0,923	1,176	1	0,077	6,131	1,780
56	Japan Tuna del Perú S. A. Agentes Marítimos	0	1*	0,646	1	0,582	0,211	0	0,418	0,870	-0,237
57	Empresa de Transporte Expreso Moderno E.I.R.L	0	0	0,560	1	0,539	0,340	1	0,461	0,653	0,112
58	GMC Ingenieros S. A.	0	1*	0,544	1	0,531	0,368	0	0,469	0,616	-0,089
59	Velca S.A.C.	0	0	0,316	1	0,914	1,004	1	0,086	5,730	1,698
60	INSASA Contratista Generales S.A.C:	0	0	0,645	1	0,581	0,212	1	0,419	0,867	0,235
61	Atlantic Unión S. A.	0	0	0,814	1	0,655	0,055	1	0,345	1,337	0,461
62	Agentes Aduaneros Universal S. A. (AGADUSA)	0	1*	0,550	1	0,534	0,357	0	0,466	0,632	-0,099
63	Servicios de Personalización Magnética S. A.	0	0	0,624	1	0,571	0,240	1	0,429	0,814	0,206
64	Horizontes S. A. Asesoría y Servicios Empresariales	0	0	0,077	1	0,969	3,118	1	0,031	9,970	2,462
65	Hotel Perú S. A:	0	0	0,680	1	0,824	0,170	1	0,176	3,254	1,108
66	F & F Publicidad S. A.	0	0	0,035	1	0,980	4,431	1	0,020	12,227	2,801
67	Industrias Texoro S. A. (INDUTEX)	0	0	0,091	1	0,965	2,861	1	0,035	9,506	2,387
68	Inversiones Mira S. A.	0	0	0,515	1	0,516	0,424	1	0,484	0,548	0,045
69	Cooperativa de Trabajo y Fomento de Empleo Atlas Ltd	0	0	0,165	1	0,948	1,931	1	0,052	7,736	2,086
70	Cia. Servicios Integral S. A.	0	1*	0,523	1	0,520	0,409	0	0,480	0,566	-0,057
71	FAA Ingeniería y Servicios Eléctricos	0	0	0,602	1	0,561	0,271	1	0,439	0,759	0,175
72	Queirolo M. S. A. Agencia de Aduanas	0	1*	0,606	1	0,562	0,266	0	0,438	0,767	-0,180
73	Agropecuaria Pilar S. A.	0	1*	0,796	1	0,791	0,067	0	0,209	2,725	-0,955
74	Avícola Rosmar S. A.	0	0	0,173	1	0,946	1,853	1	0,054	7,579	2,057
75	Del Agro Export Corp S. A.	0	0	0,582	1	0,550	0,303	1	0,450	0,708	0,145
76	Agro Guayabito S. A.	0	1*	0,497	1	0,506	0,462	0	0,494	0,507	-0,016
77	Tramsa Agro S. A.	0	1*	0,114	1	0,960	2,503	0	0,040	8,843	-2,278
78	Compañía Minera Atalaya S. A.	0	0	0,515	1	0,516	0,424	1	0,484	0,549	0,045
79	Compañía Minera Metalúrgica Huancayo S. A.	0	0	0,992	1	0,728	0,000	1	0,272	1,965	0,706
80	Urin Cañ S. R. L.	0	0	0,011	1	0,989	6,456	1	0,011	15,466	3,237

81	FABRICA NACIONAL DE ACUMULADORES ETNA S.A	1	1	0,511	1	0,868	0,431	0	0,132	4,196	-1,353
82	FABRICA PERUANA ETERNIT S.A	1	1	0,113	1	0,960	2,517	0	0,040	8,870	-2,282
83	FILAMENTOS INDUSTRIALES S.A	1	1	0,966	1	0,737	0,002	0	0,263	2,059	-0,739
84	GLORIA S.A	1	1	0,627	1	0,573	0,236	0	0,427	0,821	-0,210
85	INDUSTRIA TEXTIL PIURA S.A	1	1	0,966	1	0,737	0,002	0	0,263	2,059	-0,739
86	INDECO S.A	1	1	0,854	1	0,671	0,034	0	0,329	1,459	-0,512
87	FIMA S.A	1	1	0,517	1	0,517	0,420	0	0,483	0,553	-0,048
88	INDUSTRIAS VENCEDOR S.A	1	1	0,799	1	0,649	0,065	0	0,351	1,294	-0,442
89	LAPICES Y CONEXOS S.A. LAYCONSA	1	1	0,287	1	0,920	1,132	0	0,080	6,030	-1,760
90	LIMA CAUCHO S.A	1	1	0,662	1	0,589	0,191	0	0,411	0,913	-0,259
91	MANUFACTURA DE METALES Y ALUMINIO RECORD S.A	1	1	0,808	1	0,653	0,059	0	0,347	1,319	-0,453
92	CEMENTOS LIMA S.A.	1	1	0,756	1	0,631	0,096	0	0,369	1,170	-0,386
93	MICHELL Y CIA. S.A	1	1	0,830	1	0,662	0,046	0	0,338	1,387	-0,482
94	MOTORES DIESEL ANDINOS S.A	1	1	0,853	1	0,773	0,034	0	0,227	2,487	-0,881
95	NEGOCIACION AGRICOLA VISTA ALEGRE S.A	1	1	0,495	1	0,504	0,466	0	0,496	0,502	-0,013
96	AGRO INDUSTRIAL PARAMONGA S.A.A.	1	1	0,526	1	0,522	0,401	0	0,478	0,575	-0,062
97	EMPRESA AGRARIA AZUCARERA ANDAHUASI S.A.A	1	1	0,992	1	0,728	0,000	0	0,272	1,965	-0,706
98	CERVECERIA SAN JUAN S.A.	1	1	0,759	1	0,801	0,094	0	0,199	2,883	-1,002
99	REACTIVOS NACIONALES S.A. RENASA	1	1	0,957	1	0,709	0,003	0	0,291	1,789	-0,642
100	SOCIEDAD INDUSTRIAL DE ARTICULOS DE METAL S.A.C	1	1	0,934	1	0,701	0,007	0	0,299	1,713	-0,613
101	TEXTIL SAN CRISTOBAL S.A	1	1	0,907	1	0,756	0,014	0	0,244	2,274	-0,812
102	YURA S.A	1	1	0,729	1	0,810	0,120	0	0,190	3,021	-1,042
103	UNION DE CERVECERIAS PERUANAS BACKUS Y JOHNS	1	1	0,885	1	0,683	0,021	0	0,317	1,556	-0,551
104	SHOUGANG HIERRO PERU S.A.A	1	1	0,514	1	0,515	0,425	0	0,485	0,547	-0,044
105	Compañia Industrial Textil Credisa - Trutex S.A.A.	1	1	0,585	1	0,552	0,299	0	0,448	0,715	-0,149
106	COMPAÑIA UNIVERSAL TEXTIL S.A	1	1	0,747	1	0,627	0,104	0	0,373	1,142	-0,373
107	CONSTRUCCIONES ELECTROMECHANICAS DELCROSA S.	1	1	0,716	1	0,613	0,133	0	0,387	1,056	-0,332
108	CORPORACION ACEROS AREQUIPA S.A	1	1	0,980	1	0,718	0,001	0	0,282	1,869	-0,671
109	EXSA S.A	1	1	0,977	1	0,717	0,001	0	0,283	1,859	-0,668
110	CONSORCIO INDUSTRIAL DE AREQUIPA S.A	1	1	0,576	1	0,852	0,313	0	0,148	3,807	-1,255
111	COMPAÑIA MINERA ATACCOCHA S.A.A.	1	1	0,568	1	0,543	0,326	0	0,457	0,674	-0,125
112	COMPAÑIA MINERA MILPO S.A.A	1	1	0,872	1	0,678	0,026	0	0,322	1,515	-0,535
113	COMPAÑIA MINERA RAURA S.A	1	1	0,967	1	0,713	0,002	0	0,287	1,824	-0,655
114	COMPAÑIA MINERA SAN IGNACIO DE MOROCOCHA S.A	1	1	0,720	1	0,616	0,128	0	0,384	1,069	-0,338
115	COMPAÑIA MINERA SANTA LUISA S.A	1	1	0,914	1	0,694	0,012	0	0,306	1,648	-0,588
116	EMPRESA AGRARIA CHIQUITOY S.A	1	1	0,511	1	0,514	0,431	0	0,486	0,540	-0,039
117	EMPRESA AGRICOLA BARRAZA S.A	1	1	0,727	1	0,618	0,122	0	0,382	1,087	-0,347
118	EMPRESA AGRICOLA GANADERA SALAMANCA S.A.A	1	1	0,811	1	0,654	0,057	0	0,346	1,328	-0,456
119	ELECTRO ANDES S.. A.	1	1	0,653	1	0,831	0,202	0	0,169	3,391	-1,146
120	CONSORCIO TRANSMANTARO S.A	1	1	0,638	1	0,578	0,221	0	0,422	0,849	-0,226

121	DUKE ENERGY EGENOR SOCIEDAD EN COMANDITA	1	1	0,347	1	0,907	0,886	0	0,093	5,443	-1,637
122	EDEGEL S.A.A	1	1	0,551	1	0,534	0,356	0	0,466	0,632	-0,099
123	EDELNOR S.A.A	1	1	0,608	1	0,563	0,263	0	0,437	0,772	-0,183
124	ELECTRO SUR ESTE S.A.A	1	1	0,836	1	0,779	0,043	0	0,221	2,558	-0,904
125	ELECTRO SUR MEDIO S.A.A.	1	1	0,847	1	0,775	0,037	0	0,225	2,513	-0,889
126	EMPRESA EDITORA EL COMERCIO S.A	1	0*	0,487	1	0,500	0,484	1	0,500	0,485	0,000
127	EMPRESA ELECTRICA DE PIURA S.A	1	1	0,589	1	0,848	0,292	0	0,152	3,732	-1,236
128	EMPRESA REGIONAL DE SERVICIO PUBLICO DE ELECTR	1	1	0,885	1	0,763	0,021	0	0,237	2,361	-0,841
129	EMPRESA REGIONAL DE SERVICIO PUBLICO DE ELECTR	1	1	0,600	1	0,560	0,274	0	0,440	0,753	-0,172
130	SHOUGANG GENERACION ELECTRICA S.A.A	1	1	0,769	1	0,799	0,086	0	0,201	2,841	-0,990
131	EMPRESA SIDERURGICA DEL PERU S.A.A. - SIDERPERU	1	1	0,640	1	0,579	0,219	0	0,421	0,853	-0,228
132	FERREYROS S.A.A	1	1	0,707	1	0,609	0,141	0	0,391	1,032	-0,320
133	ALICORP S.A.A.	1	1	0,617	1	0,568	0,250	0	0,432	0,795	-0,196
134	AMERICA LEASING S.A.	1	0*	0,559	1	0,539	0,341	1	0,461	0,652	0,112
135	AUSTRAL GROUP S.A.A.	1	0*	0,570	1	0,544	0,323	1	0,456	0,678	0,128
136	GRAÑA Y MONTERO S.A.A	1	1	0,329	1	0,911	0,953	0	0,089	5,608	-1,672
137	HIDROSTAL S.A	1	1	0,425	1	0,889	0,638	0	0,111	4,797	-1,494
138	INCA TOPS S.A.A	1	1	0,670	1	0,593	0,181	0	0,407	0,933	-0,270
139	INMOBILIARIA MILENIA S.A	1	1	0,001	1	0,995	10,117	0	0,005	20,908	-3,877
140	INTRADEVCO INDUSTRIAL S.A	1	1	0,984	1	0,719	0,000	0	0,281	1,881	-0,676
141	INVERSIONES CENTENARIO S.A.A	1	1	0,907	1	0,756	0,014	0	0,244	2,276	-0,813
142	INVERSIONES EN TURISMO S.A. INVERTUR	1	0*	0,558	1	0,538	0,344	1	0,462	0,649	0,110
143	INVERSIONES NACIONALES DE TURISMO S.A. INTURSA	1	1	0,536	1	0,527	0,382	0	0,473	0,598	-0,077
144	LUZ DEL SUR S.A.A	1	1	0,603	1	0,561	0,271	0	0,439	0,759	-0,175
145	PROMOTORA CLUB EMPRESARIAL S.A	1	1	0,497	1	0,506	0,461	0	0,494	0,508	-0,017
146	QUIMPAC S.A	1	1	0,575	1	0,547	0,314	0	0,453	0,691	-0,135
147	RANSA COMERCIAL S.A	1	1	0,581	1	0,550	0,304	0	0,450	0,706	-0,144
148	NEGOCIOS E INMUEBLES S.A	1	1	0,053	1	0,975	3,757	0	0,025	11,089	-2,634
149	PERU HOLDING DE TURISMO S.A.A	1	1	0,270	1	0,924	1,219	0	0,076	6,229	-1,800
150	PERUBAR S.A	1	1	0,030	1	0,982	4,710	0	0,018	12,687	-2,866
151	RED BICOLOR DE COMUNICACIONES S.A.A.	1	1	0,055	1	0,975	3,695	0	0,025	10,983	-2,618
152	LP HOLDING S.A	1	0*	0,862	1	0,771	0,030	1	0,229	2,453	0,870
153	LOS PORTALES S.A	1	1	0,830	1	0,780	0,046	0	0,220	2,581	-0,911
154	ABB S.A.	1	1	0,642	1	0,580	0,216	0	0,420	0,859	-0,231
155	SAGA FALABELLA S.A	1	1	0,553	1	0,536	0,352	0	0,464	0,638	-0,103
156	SOCIEDAD INDUSTRIAL DE ARTICULOS DE METAL S.A.C	1	1	0,934	1	0,701	0,007	0	0,299	1,713	-0,613
157	CONSORCIO AGUA AZUL S.A	1	0*	0,976	1	0,733	0,001	1	0,267	2,021	0,726
158	TICINO DEL PERU S.A	1	1	0,001	1	0,996	10,376	0	0,004	21,279	-3,917
159	SOUTHERN PERU COPPER CORPORATION	1	1	0,847	1	0,775	0,037	0	0,225	2,512	-0,889
160	TC SIGLO 21 S.A.A	1	1	0,522	1	0,519	0,410	0	0,481	0,564	-0,055

* Empresa mal clasificada

**ANEXO N° 08
CLASIFICACION DE LAS 28 EMPRESAS PARA LA VALIDACION**

N°	EMPRESA	Liquidez	Solvencia		COND	SECTOR	FCL1	FCL2	GRUPO PRONOSTICADO
		Raz Corr	Raz End	RAF					
1	Cobres Laminados S. A. (COBRELSA)	0,45	0,95	1,25	0	1	-1,532	-1,251	1*
2	Cartones Nacionales S. A. (CARTONSA)	0,07	0,95	0,00	0	1	-1,377	-1,665	0
3	Procesadora Yancay S. R. Ltda.	0,00	1,75	0,02	0	1	-1,049	-1,646	0
4	Industria Selva S. A. (INDULSEL)	0,41	1,16	1,86	0	1	-1,425	-1,269	1*
5	Industrias de Granos Alimenticios S. A. C. (IGASAC)	0,81	0,92	4,98	0	1	-1,644	-0,860	1*
6	Fortuna Internacional S. A.	0,01	69,35	0,00	0	2	23,890	6,341	0
7	Vale S. A.	0,65	1,58	34,69	0	2	-0,791	-0,926	0
8	Fumiport S. A.	1,26	0,80	0,00	0	2	-1,988	-0,390	1*
9	Braco S. R. L. Seguridad Industrial	0,26	2,47	8,09	0	2	-0,759	-1,271	0
10	Protecto S. A.	0,71	1,39	11,95	0	2	-1,299	-0,906	1*
11	Clinica los Pinos S. A.	0,88	2,11	2,27	0	2	-1,287	-0,646	1*
12	Alerta Médica S. A.	0,25	1,96	5,21	0	2	-0,995	-1,345	0
13	Pesquera Trece S. A.	0,76	1,08	0,70	0	3	-1,639	-0,900	1*
14	Gerencia y Representaciones Pesqueras S. A. (GERPESA)	0,51	1,11	0,91	0	3	-1,507	-1,167	1*
15	CORPORACION CERAMICA S.A	3,33	0,19	2,75	1	1	-3,133	1,793	1
16	CORPORACION JOSE R. LINDLEY S.A	0,56	0,57	1,02	1	1	-1,728	-1,176	1
17	AGROINDUSTRIAS SAN JACINTO S.A.A.	0,98	0,38	0,22	1	1	-2,008	-0,743	1
18	EMPRESA AGROINDUSTRIAL LAREDO S.A.A	0,54	0,37	0,34	1	1	-1,808	-1,218	1
19	COMPAÑIA GOODYEAR DEL PERU S.A.	3,55	0,21	4,59	1	1	-3,193	2,032	1
20	EMPRESA AGRICOLA SAN JUAN S.A	1,16	0,11	0,22	1	3	-2,193	-0,575	1
21	EMPRESA AGRICOLA SINTUCO S.A	0,95	0,31	0,22	1	3	-2,022	-0,784	1
22	TELEFONICA MOVILES S.A	0,34	0,63	0,66	1	2	-1,610	-1,411	1
23	CEMA COMUNICACIONES S. A.	4,44	0,06	4,90	1	2	-3,658	2,981	1
24	INDUSTRIAS DEL ENVASE S.A	1,00	0,41	1,23	1	2	-1,989	-0,716	1
25	INDUSTRIAS ELECTRO QUIMICAS S.A. IEQSA	1,03	0,60	1,14	1	2	-1,931	-0,667	1
26	METALURGICA PERUANA S.A	0,69	0,59	0,78	1	2	-1,786	-1,029	1
27	BAYER S. A.	1,97	0,48	26,46	1	2	-1,962	0,370	1
28	BRITISH AMERICAN TOBACCO DEL PERU HOLDINGS S.A.A.	2,34	0,41	4,19	1	2	-2,561	0,741	1

* Empresa mal clasificadas

FCL : Función de Clasificación Lineal