

## Modelos de Previsão do Fracasso Empresarial: Aspectos a considerar

José Manuel Pereira<sup>1</sup>, Miguel Á. Crespo Domínguez<sup>2</sup>, José L. Sáez Ocejo<sup>3</sup>

jpereira@ipca.pt, macrespo@uvigo.es, jocejo@uvigo.es

(Recebido em 30 de Março de 2007; Aceite em 8 de Maio de 2007)

**Resumo.** A previsão do fracasso empresarial é um tema que interessa cada vez mais aos diversos agentes económicos, em particular aos investidores, credores, entidades financeiras, mas também aos governos. Desde o trabalho pioneiro de Beaver (1966) diferentes métodos têm sido utilizados: análise discriminante, *logit*, *probit*, redes neuronais, indução de regras e árvores de decisão, algoritmos genéticos, conjuntos aproximados, entre outros modelos. O nosso objectivo é efectuar uma comparação dos métodos que têm sido mais utilizados, analisando as principais vantagens e inconvenientes bem como a sua aplicabilidade para os potenciais utilizadores. Concluimos que a capacidade predictiva dos modelos é em geral similar e que a maioria dos investigadores utilizou a análise discriminante ou o *logit*. Em geral, e para um utilizador comum, os modelos baseados em redes neuronais revelam-se difíceis de aplicar.

**Palavras-chave:** Fracasso Empresarial; Análise Discriminante; *Logit*; *Probit*; Redes Neuronais; Árvores de Decisão.

**Abstract.** Prediction of corporate bankruptcy is a phenomenon of increasing interest to investors, creditors, borrowing firms, and governments alike. Since the seminal work of Beaver (1966) different techniques have been used: discriminant analysis, *logit*, *probit*, neural networks, decision trees, genetic

---

<sup>1</sup> Escola Superior de Gestão do Instituto Politécnico do Cávado e Ave (IPCA)

<sup>2</sup> Universidade de Vigo, Espanha

<sup>3</sup> Universidade de Vigo, Espanha

algorithms, rough sets, and some other techniques. Our intent is to provide a comparison of the most popular methods, analysing their own strengths and weaknesses and their applicability to potential users. We find that predictive accuracies of different models seem to be generally comparable and the use of discriminant analysis and *logit* models dominates the research. In general the neural networks models are the most difficult for the users.

**Keywords:** Bankruptcy; Discriminant Analysis; *Logit*; *Probit*; Neural Networks; Decision Trees.

## 1. Introdução

O problema do fracasso empresarial tem sido, e seguramente continuará a ser, um tema de especial interesse para um amplo conjunto de agentes económicos. O fracasso das empresas pode resultar de um conjunto de causas diversas e complexas, de natureza interna e externa, podendo ser imputado, por exemplo, a uma deficiente estrutura organizativa, à própria estratégia da empresa, modificações tecnológicas ou à evolução da conjuntura económica.

A elaboração de modelos de previsão do fracasso empresarial é um campo de investigação que foi impulsionado pelos trabalhos pioneiros de Beaver (1966) e Altman (1968) sendo crescente o número de investigadores que se interessam por esta temática.

Nestas quatro décadas muitos foram os trabalhos publicados, com aperfeiçoamentos metodológicos que nem sempre foram acompanhados de uma melhoria nos resultados. Talvez, por isso, os investigadores tenham procurado nos últimos anos técnicas e ferramentas alternativas com o objectivo de incorporar nos modelos elaborados maior utilidade e precisão.

Neste trabalho abordaremos os principais problemas que surgem quando se pretende elaborar um modelo de previsão do fracasso empresarial, tendo por base a estrutura da maioria dos trabalhos de investigação nesta área, nomeadamente, a definição de fracasso utilizada, a composição da amostra, as variáveis seleccionadas ou as técnicas a aplicar.

## 2. Objectivo dos estudos

Foi a partir da década de sessenta que surgiram os principais estudos sobre a previsão do fracasso empresarial. Na maioria dos trabalhos aplicaram-se técnicas estatísticas ou de *data mining* aos dados contabilísticos das empresas, com o objectivo de obter modelos de previsão que permitissem dar indicações sobre se uma empresa poderá ou não chegar a uma situação de insolvência no futuro (Beaver, 1966; Altman, 1968; Blum, 1974; Martin, 1977; Tan & Kiang, 1992, entre outros).

No entanto, nem todos os estudos perseguiram o objectivo supra referido. Alguns dos primeiros trabalhos tinham como objectivo provar se os dados contabilísticos continham informação sobre a futura solvência da empresa. Noutros estudos compararam-se modelos para discriminar entre as melhores alternativas (Frydman *et al.*, 1985; Gentry *et al.*, 1985; Aly *et al.*, 1992; Koh & Tan, 1999; Charitou *et al.*, 2004), outros tentaram comprovar a eficácia de alguns modelos ao longo do espaço e do tempo (Lizarraga, 1998; Grice & Dugan, 2001). Há também estudos que se propuseram desenvolver uma formulação teórica que possibilitasse a explicação dos resultados (Wilcox, 1971; Santomero & Vinso, 1977).

Sempre que o objectivo do investigador passe pela elaboração de um modelo com o propósito de ser utilizado para tomar decisões concretas, por exemplo, concessão ou não concessão de um crédito a uma empresa, haverá que ter em conta, como refere Mora (1994), que nestas situações as limitações dos modelos adquirem uma maior relevância, e os erros de classificação nestes casos têm uma transcendência económica real.

## 3. Definição de fracasso

Num estudo sobre previsão do fracasso empresarial um dos primeiros aspectos que temos necessidade de definir é o conceito de fracasso que se vai utilizar. Como exemplo, Beaver (1966) utilizava uma definição de fracasso que englobava a falta de pagamento aos credores, a existência de contas bancárias a descoberto, o não pagamento de dividendos a capital preferencial ou a falência jurídica. Outros autores como Altman (1968), Deakin (1972), Zavgren (1985) e Aziz & Lawson (1989) recorreram à falência jurídica. Lizarraga (1995), Gallego *et al.* (1997) e Somoza & Vallverdú (2003) utilizaram a suspensão de pagamentos ou a falência jurídica.

Pode-se verificar que a definição de fracasso empresarial tem sido abordada de diversas maneiras por distintos autores: falência jurídica, insolvência, suspensão de pagamentos ou perdas continuadas. Como afirma Rodríguez (1994:C-701) “en-

quanto alguns autores se referem ao fracasso partindo do conceito de suspensão de pagamentos, outros consideram o fracasso a falência jurídica; há também os que se referem à falta de pontualidade nos pagamentos por parte da empresa, ou inclusive aqueles que admitem o fracasso em empresas que registaram perdas durante alguns anos consecutivos.”<sup>1</sup>

Perante a ausência de uma teoria geral do fracasso empresarial não há uma definição única para este conceito. Esta é uma limitação importante, uma vez que a selecção da amostra, tanto para as empresas não fracassadas como para as empresas fracassadas depende da definição que se utilize de fracasso empresarial.

Para Laffarga (1999) esta limitação pode ser ultrapassada realizando uma análise prévia dos grupos e assegurando-se que o grupo das empresas fracassadas é constituído por empresas que atravessam dificuldades financeiras, e que o grupo das empresas não fracassadas contém apenas entidades que têm uma boa situação económica e financeira.

Uma vez definido o conceito de fracasso empresarial que se vai utilizar, a continuação do estudo deve-se centrar nos aspectos relacionados com a composição da amostra, tema que analisaremos no próximo ponto.

## **4. Composição da amostra**

### **4.1 Tipos de empresas objecto de estudo**

Ao analisar os trabalhos publicados sobre o presente tema verifica-se que as entidades objecto de estudo podem-se enquadrar essencialmente em três tipos: empresas seguradoras (Rodríguez, 1990; López *et al.*, 1994; Mora, 1994), empresas financeiras e de crédito (Laffarga *et al.*, 1985; Rodríguez, 1989; Pina, 1989; Serrano, 1994) e empresas não financeiras.

Sobre as empresas não financeiras há trabalhos que utilizam empresas industriais (Blum, 1974), empresas comerciais (McGurr & DeVaney, 1998; Bhargava *et al.*, 1998), empresas cotadas na Bolsa (Fernández *et al.*, 1996; Kim & Kim, 1999) ou empresas de um sector específico (Scherr, 1989; Somoza & Vallverdú, 2003) entre outros.

Há também trabalhos que utilizam os dados de empresas pertencentes a diferentes sectores de actividade (Frank, 1969; Elam, 1975; Dambolena & Khoury, 1980;

---

<sup>1</sup> Em todas as citações de autores estrangeiros, a tradução é nossa.

Keasey & McGuinness, 1990; Baldwin & Glezen, 1992). No entanto, este procedimento apresenta o inconveniente de não ter em consideração as particularidades de cada sector, já que os valores dos rácios dependem do sector a que pertence a empresa (Laffarga & Mora, 1998). Por outro lado, a composição da amostra pode estar influenciada por um determinado sector, o que pode comprometer a aplicação do modelo obtido a um sector que tenha uma fraca representação na mesma (Román & De La Torre, 2002).

#### 4.2 A selecção da amostra

Para a realização de um trabalho empírico sobre a previsão do fracasso empresarial é necessário uma amostra de empresas sobre a qual se vai desenvolver o modelo. Como afirma Galindo & Drozdowskyj (2002) a eficácia do mesmo depende da qualidade da amostra e para isso é necessário ter informação fiável sobre o universo das empresas a ser investigado.

Nesta fase da investigação temos que formular, entre outras, as seguintes perguntas: como seleccionar as empresas fracassadas e as não fracassadas?, qual a dimensão da amostra?, que sector de actividade vai ser estudado? ou se as empresas serão emparelhadas ou não?

Relativamente às empresas fracassadas, a selecção da amostra poderia ser feita em função da definição de fracasso que se estivesse a utilizar <sup>2</sup>.

Sobre as empresas não fracassadas Taffler (1982) refere que a amostra destas deve incluir unicamente empresas sem dificuldades financeiras, uma vez que as empresas que apresentam algum tipo de dificuldade financeira momentânea, podem ter similares características com as empresas fracassadas da amostra, o que pode conduzir a resultados incorrectos.

Outra questão é se a amostra é representativa das empresas objecto de estudo. Na situação ideal a amostra de empresas, tanto não fracassadas como fracassadas, deveria seleccionar-se de forma aleatória.

Na maioria dos estudos relacionados com a previsão do fracasso, utilizam-se amostras com o mesmo número de empresas fracassadas e não fracassadas (Altman, 1968; Blum, 1974; Messier & Hausen, 1988; Salchenberger *et al.*, 1992; Altman *et al.*, 1994; McKee, 1995; Gallego *et al.*, 1997). Com esta metodologia a amostra

---

<sup>2</sup> Gabás (1997) refere que se utilizam variadas definições em função dos objectivos e da disponibilidade dos dados.

seleccionada não tem a mesma percentagem de empresas fracassadas e não fracassadas da população original, o que significa que uma empresa fracassada da população tem mais probabilidades de fazer parte da amostra que uma empresa não fracassada (Zmijewski, 1984).

No entanto, ao seleccionar-se uma amostra aleatória da população, as empresas fracassadas que faziam parte da amostra poderiam ser de tamanho e sector muito diferente das empresas não fracassadas, e como afirma Mora (1994) as diferenças entre os valores das variáveis independentes das amostras poderiam atribuir-se, não unicamente ao facto de as empresas se encontrarem numa situação de “fracasso” ou “não fracasso”, mas também a diferenças sectoriais e de tamanho entre as mesmas.

Para evitar o problema sectorial pode-se seleccionar a amostra de um determinado sector ou emparelhar as empresas fracassadas com empresas não fracassadas do mesmo sector. Em geral, as empresas fracassadas e as empresas não fracassadas são emparelhadas, não apenas por sector, mas também por tamanho (Renart, 2003).

### 4.3 Métodos de amostragem e de validação dos resultados

Regra geral, a validação dos resultados dos modelos faz-se através de uma amostra secundária que pode ser contemporânea ou posterior à inicial.

Também existem estudos em que os resultados apenas se aplicam à amostra que serviu de base à construção do modelo (Beaver, 1966; Sinkey, 1975; Gentry *et al.*, 1985), que é um método pouco recomendável, uma vez que se o conjunto de teste e de validação se basear nos mesmos exemplos, os resultados serão logicamente demasiado optimistas.

A maioria das técnicas de *data mining* disponibiliza vários métodos de amostragem<sup>3</sup>, dos quais destacamos os seguintes:

- *Holdout* – O estimador *holdout* divide os exemplos numa percentagem fixa de exemplos  $p$  para treino e  $(1 - p)$  para validação, considerando normalmente  $p > 1/2$ . Os valores mais usuais são  $p = 2/3$  e  $(1 - p) = 1/3$  (Flexer, 1996), apesar de não existirem fundamentos teóricos sobre os referidos valores.

- *Cross-Validation* – O método *Cross-Validation* (Validação Cruzada) (Figura 1) permite a utilização de todos os elementos disponíveis. De acordo com Santos


---

<sup>3</sup> Existem outros métodos, tais como: Amostragem aleatória, *Stratified Cross-Validation*, *Leave-One-Out* e *Bootstrap*, que podem ver-se em (Flexer, 1996; Santos & Azevedo, 2005; Quintela, 2005).

& Azevedo (2005) na validação cruzada K-desdobrável, os exemplos (P) são divididos em K subconjuntos mutuamente exclusivos ( $P_1, P_2, \dots, P_k$ ) de dimensões aproximadamente iguais (*K-folds*). Os modelos são treinados e validados K vezes e o erro final de generalização obtém-se pela média dos erros de validação obtidos durante K vezes. Os valores de K podem variar entre 2 e n, embora o valor 10 seja o mais popular (*Ten-Fold Cross-Validation*). Para Cortez (2002) a validação cruzada é notavelmente superior à validação com divisão da amostra para pequenos conjuntos de exemplos de treino, sendo conseguida através de um considerável esforço computacional.

Este método permite-nos seleccionar os parâmetros do modelo que tenha obtido melhores resultados, uma vez que se obtêm K funções. Consequentemente, deixaremos de contar com uma amostra para validação dado que o modelo seleccionado se vai aplicar à amostra total.

Figura 1 – Validação cruzada com K iterações



Fonte: Santos & Azevedo (2005)

Após a elaboração do modelo é necessário validar o seu desempenho, sendo a matriz de confusão uma das técnicas mais populares.

A matriz de confusão de um classificador indica o número de classificações correctas versus as previsões efectuadas para cada caso, sobre um conjunto de exemplos T (Kohavi & Provost, 1998).

Nesta matriz as linhas representam os casos reais e as colunas as previsões efectuadas pelo modelo. O número de acertos para cada caso está indicado na diagonal principal da matriz. A matriz de confusão de um classificador ideal possui todos os restantes elementos iguais a zero.

Como exemplo, considere-se um problema com dois casos identificados com “+” (positivo) e “-” (negativo), onde as possibilidades de acerto e erro resumem-se

a quatro indicadores (Santos & Azevedo, 2005):

- Verdadeiros Positivos, designados por TP (*True Positive*), correspondem ao número de exemplos positivos classificados correctamente;
- Verdadeiros Negativos, designados por TN (*True Negative*), correspondem ao número de exemplos negativos classificados como negativos (correctamente);
- Falsos Positivos, designados por FP (*False Positive*), representam o número de exemplos positivos classificados como negativos (mal classificados);
- Falsos Negativos, designados por FN (*False Negative*), representam o número de exemplos negativos mal classificados (classificados como positivos).

A tabela 1 apresenta uma matriz de confusão para um problema com dois casos e  $n=(TP+FN+FP+TN)$  exemplos.

Tabela 1 – Matriz de confusão

<b>Previsão</b>	<b>Positivo</b>	<b>Negativo</b>
<b>Real</b>		
<b>Positivo</b>	<b>TP</b>	FN
<b>Negativo</b>	FP	<b>TN</b>

Com base na matriz de confusão é possível calcular as seguintes medidas<sup>4</sup>:

$$\text{Especificidade (erro Tipo I)} = \frac{TN}{TN + FP} * 100\%$$

$$\text{Sensibilidade (erro Tipo II)} = \frac{TP}{TP + FN} * 100\%$$

$$\text{Acuidade ou Precisão} = \frac{TP + TN}{n} * 100\%$$

$$\text{Taxa de erro total} = \frac{FP + FN}{n} * 100\%$$

---

<sup>4</sup>Estas e outras medidas derivadas da referida matriz podem ver-se em (Weiss & Kulikowsky, 1991).



#### 4.4 Dimensão da amostra

Para qualquer dos métodos que iremos analisar é importante dispor de uma amostra representativa do total de empresas, uma vez que o erro diminui quando a amostra se aproxima do universo a ser investigado. Quanto maior é o número de variáveis explicativas ou independentes, maior deveria ser a amostra seleccionada.

Então poderemos questionar qual será a dimensão da amostra necessária ou, simplesmente, suficiente para elaborar um modelo de previsão do fracasso empresarial.

Em alguns modelos há autores que recomendam para a dimensão da amostra valores mínimos ou razoáveis. Eidleman (1995) refere que é necessária uma amostra de aproximadamente 30 exemplos para que os resultados tenham validade estatística. Por sua vez, Hair *et al.* (1998) afirmam que para a análise discriminante o tamanho mínimo recomendado é de 5 observações por variável independente e como regra prática cada grupo deve ter pelo menos 20 observações.

Sobre as redes neuronais, Cortez (2002) sugere a utilização de amostras de treino significativas, com centenas ou mesmo milhares de exemplos. Para Coats & Fant (1993) o tamanho de uma amostra para aprendizagem de uma rede neuronal artificial não deverá ser inferior a 30, dado que um número pequeno de exemplos para treino conduz a *sobre-ajustamento (overfitting)* e nestas situações a rede perde poder de generalização. Segundo Berry & Linoff (2000) deverão existir no mínimo 10 exemplos de treino por cada peso<sup>5</sup> na rede. Por sua vez, Baum & Haussler (1989) referem que o tamanho da amostra deverá ser no mínimo igual ao quociente entre o número de conexões na rede e a proporção entre as duas amostras.

Como podemos verificar não há um grande consenso entre os diversos autores sobre esta matéria. No entanto, das diversas opiniões podemos concluir que, em princípio, quanto maior a amostra melhor.

Outra questão importante relaciona-se com a utilização de amostras fortemente desproporcionadas. Segundo O'Leary (1998) uma baixa proporção de empresas fracassadas resulta em modelos que geralmente prevêm que quase todas as empresas são não fracassadas. Consequentemente, podemos esperar dos modelos elaborados com uma pequena percentagem de empresas fracassadas pouca precisão em populações com elevadas percentagens de empresas falidas. Esta conclusão pode ver-se, por exemplo, em (Boritz *et al.*, 1995) que fizeram a experiência com percentagens de empresas fracassadas que variaram de 1% até 50% (1%, 5%, 10%, 20%, 33% e

---

<sup>5</sup> Cada ligação entre os neurónios tem associado um peso.

50%) e também em (Wilson & Sharda, 1994) que utilizaram percentagens de empresas fracassadas de 10%, 20% e 50%.

Estas posições são muito diferentes das de Zmijewski (1984) que criticou a utilização de amostras com dimensões muito distintas da população original. Uma forma de tentar conciliar estas duas perspectivas seria a utilização na fase de treino de amostras relativamente balanceadas e efectuar a validação em amostras cujas percentagens se aproximassem da população original.

## 5. As variáveis utilizadas

Outra questão importante na elaboração de estudos de previsão do fracasso empresarial relaciona-se com a selecção das variáveis independentes, isto é, que variáveis farão parte do modelo.

Segundo Laffarga & Mora (1998:32), “a maior parte dos trabalhos analisados utilizam para a selecção das variáveis independentes os mesmos critérios utilizados por Beaver, e em muitos casos acrescenta-se como critério a preferência dos investigadores por um ou outro rácio”.<sup>6</sup>

Os rácios económico-financeiros são os indicadores que se utilizam com mais frequência como variáveis independentes nos diversos modelos. Relativamente a este aspecto, poderíamos formular as seguintes perguntas: como realizar a selecção dos rácios?, que grupo de rácios tem sido mais utilizado nos vários estudos?, que rácios têm funcionado bem em estudos prévios? ou é útil a inclusão de outro tipo de variáveis?

Na selecção dos rácios haverá que ter em conta a possível correlação entre as variáveis, que pode produzir problemas de estimação, uma vez que um alto grau de correlação (multicolinearidade) entre duas ou mais variáveis independentes torna difícil distinguir os efeitos individuais de cada uma delas sobre a variável dependente. Contudo, não devemos sobrestimar o efeito da multicolinearidade, uma vez que para o analista a questão mais importante deverá ser o determinar se um rácio contribui ou não para a explicação da variável dependente. Se se confirma a sua contribuição e apesar da multicolinearidade é preferível, em geral, incorporar a variável no modelo, pois desta forma aumentar-se-á o seu poder predictivo que é o principal objectivo do analista (Lev, 1978). Para Benishay (1971) se nos modelos

---

<sup>6</sup> Beaver (1966) utilizou os seguintes critérios para a selecção das variáveis independentes: popularidade na literatura, desempenho em estudos prévios e adesão ao conceito de *cash-flow*.

econométricos apenas incluímos os rácios que sejam completamente independentes, perde-se o possível conteúdo informativo que possa existir em rácios semi-independentes.

Sobre os rácios que tenham apresentado um bom comportamento em estudos prévios, a evidência empírica permite constatar que em diversos modelos obtiveram-se rácios similares como variáveis explicativas. Ao analisar vários trabalhos produzidos em Espanha durante os anos oitenta e noventa, Laffarga & Mora (1998) afirmam que, independentemente da amostra, do modelo ou dos aspectos metodológicos escolhidos, todos eles concluem que são os rácios de rentabilidade e os de liquidez os melhores indicadores para discriminar entre empresas não fracassadas e fracassadas.

Os rácios apresentam como principais vantagens a facilidade tanto de cálculo como de comparabilidade. No entanto, como refere Laffarga (1999) convém ter presente os inconvenientes que os mesmos podem apresentar: a ausência de uma teoria que ajude na selecção das variáveis, os problemas relacionados com a distribuição dos rácios bem como as diferenças sectoriais e de tamanho entre as empresas.

As variáveis independentes dos modelos de previsão de fracasso não são formadas apenas pelos rácios financeiros. Existem diversos estudos que consideram também outro tipo de variáveis distintas dos rácios financeiros, como sejam as variáveis qualitativas e/ou variáveis externas.

Keasey & Watson (1987) afirmam que não está claro que um adequado modelo de previsão se possa basear unicamente em rácios financeiros, tendo demonstrado que os modelos que continham variáveis qualitativas apresentavam uma capacidade de previsão superior ao modelo que continha unicamente rácios financeiros.

No seu modelo de redes neuronais, Nuñez (1997) também utilizou variáveis qualitativas. Outro autor que utilizou este tipo de variáveis foi Somoza (2002) onde analisa as hipóteses se a inclusão de variáveis qualitativas e de variáveis externas permite aumentar a capacidade predictiva dos modelos baseados em rácios. Os resultados obtidos com a inclusão de variáveis qualitativas indicaram um incremento da capacidade predictiva dos modelos. Com a utilização de variáveis externas, macroeconómicas e sectoriais, os resultados não foram tão animadores.

## **6. As técnicas aplicadas**

Após a publicação em 1968 do Z-Score de Altman, a maioria dos trabalhos que se seguiram na década seguinte utilizaram também a análise discriminante.

O surgimento de trabalhos críticos enfatizando as limitações desta teoria terá influenciado os investigadores a experimentar outras técnicas. A evolução tecnoló-

gica e informática propiciaram também as condições necessárias para o desenvolvimento e aplicação de outras técnicas que, embora não isentas de limitações, não necessitam que se cumpram alguns dos pressupostos das técnicas estatísticas.

Neste ponto iremos analisar alguns aspectos que deveremos ter em conta no momento de decidir sobre o método que se vai aplicar. Embora existam outros métodos, os mais utilizados dentro das técnicas estatísticas são a Análise Discriminante, *Logit* e *Probit* e nas técnicas de *data mining* as Redes Neurais e a Indução de Regras e Árvores de Decisão. Por este motivo as considerações que faremos de seguida referem-se apenas a estas cinco técnicas.

## 6.1 Fundamentos e considerações sobre as técnicas

### Análise Discriminante

Os fundamentos técnicos deste tipo de análise podem ser apresentados, de forma resumida, da seguinte maneira: a análise discriminante pode ser compreendida como um sistema de pontuações que, a cada elemento, faz corresponder uma pontuação resultante de uma média ponderada dos valores que, para ela, assumem as variáveis independentes. Segundo Reis (1997) se considerarmos as variáveis discriminantes como eixos definindo um espaço  $p$ -dimensional, cada caso poderá ser representado nesse espaço por um ponto cujas coordenadas são dadas pelos valores das  $p$  variáveis para esse mesmo indivíduo. Se os vários grupos em estudo apresentarem um comportamento diferenciado relativamente a essas variáveis é possível imaginar cada grupo representado por um aglomerado de pontos com contornos relativamente nítidos e separados dos restantes grupos. Embora os grupos possam ter alguns elementos sobrepostos, é possível identificar os seus territórios e posicioná-los a partir de uma medida da sua posição típica descritiva, o centróide de cada grupo.

O centróide corresponde à média aritmética das variáveis discriminantes para os elementos pertencentes ao mesmo grupo. A distância entre os centróides dos dois grupos permite verificar a significância estatística das funções discriminantes.

A melhor combinação linear de variáveis independentes para discriminar elementos pertencentes a diferentes grupos é aquela que permite minimizar os erros de uma incorrecta classificação. Para isso e de acordo com Reis (1997) é necessário que se cumpram as seguintes hipóteses:

- As variáveis discriminantes têm que ter uma distribuição normal multivariada;
- Dentro dos grupos a variabilidade deverá ser similar, isto é, as matrizes de variância e covariância de cada grupo têm de ser aproximadamente iguais;

- Nenhuma variável discriminante poderá ser combinação linear das outras;
- O número de elementos em cada grupo tem que ser dois ou mais;
- É necessário que haja pelo menos dois grupos;
- Pode-se utilizar qualquer número de variáveis discriminantes ( $p$ ), desde que o seu número seja inferior ao número total de casos ( $n$ ) menos dois ( $0 < p < n-2$ ).

### Modelo Logit

O *logit* obtém-se a partir da regressão logística. Esta pode ser utilizada quando a variável dependente é binária ou dicotómica (Hosmer & Lemeshow, 1989). O procedimento que calcula os coeficientes logísticos compara a probabilidade de um evento suceder com a probabilidade de não suceder e designa-se por *odds ratio* (Hair *et al.*, 1998).

Como refere Ferrando & Blanco (1998) num modelo *logit*, a relação entre a probabilidade de fracasso numa empresa  $i$  ( $P_i$ ) e o valor dos  $j$  *ratos* financeiros dessa empresa num determinado ano ( $X_{ji}$ ) resulta numa curva em forma de S entre zero e um, e pode ser representada pela expressão [1]:

$$P_i = \text{Prob} [Y_i = 1 / (X_{1i}, X_{2i}, \dots, X_{mi})] = \frac{1}{1 + e^{-z_i}} \quad [1]$$

A expressão [2] resulta da substituição de  $Z_i$  por uma relação linear, na qual  $\alpha$  e  $\beta_i$  representam os coeficientes a estimar.

$$P_i = \frac{1}{1 + e^{-(\alpha + \sum \beta_i X_i)}} \quad [2]$$

Como já referimos, para obter o *logit* a partir do modelo logístico, teremos que fazer uma transformação ao modelo. Essa transformação, designada por *Logit*  $P_i$  é dada pelo logaritmo natural da divisão de  $P_i$  pelo seu complementar ( $1 - P_i$ ) (Kleinbaum, 1996).

### Modelo Probit

Este tipo de análise de regressão também é apropriado para conjuntos de dados em que a variável dependente é do tipo binário, dicotómico ou *dummy* (Nelson, 1990). O modelo *probit* está associado à função cumulativa de probabilidade normal, pressupondo uma distribuição normal.

No *probit* a derivada da probabilidade em relação a um  $X_k$  específico no conjunto das variáveis  $X$  é:

$$\frac{\partial \Phi(X\beta)}{\partial X_k} = \phi(X\beta)\beta_k \quad [3]$$

onde

$$\phi(z) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}z^2\right) \quad [4]$$

é a função densidade normal padrão.

Neste modelo a derivada da probabilidade em ordem a  $X$  varia com o nível de  $X$  e com as outras variáveis do modelo. Uma consequência prática desta diferença é que, em geral, não é útil apresentar apenas os coeficientes do modelo *probit*, a não ser que se esteja apenas interessado no sinal dos coeficientes (Johnston & DiNardo, 2001).

## Redes neuronais

Embora ainda se ignore muito sobre a forma como o cérebro humano aprende a processar a informação, tem-se desenvolvido modelos que tentam imitar tais habilidades, denominados redes neuronais artificiais<sup>7</sup> ou modelos de computação conexionista. A elaboração destes modelos supõe, por um lado, a dedução das características essenciais dos neurónios e suas conexões e, por outro, a implementação do modelo num computador de forma que se possa simular.

Os princípios que ainda hoje vigoram sobre as redes neuronais artificiais foram apresentados pela primeira vez por Warren McCulloch e Walter Pitts em 1943, e demonstraram que as redes neuronais artificiais podem calcular qualquer função aritmética ou lógica (Hagan *et al.*, 1996).


O elemento de processamento numa rede neuronal artificial é um neurónio (Figura 2), onde as entradas do neurónio correspondem ao vector de entrada  $X =$

---

<sup>7</sup>Assim designado para distinguir entre o modelo natural (cérebro) e o artificial (rede).

$[x_1, x_2, \dots, x_n]$  de dimensão  $n$ . Para cada uma das entradas  $x_i$ , há um peso correspondente  $w_i$ . Este peso simula a sinapse (conexão) entre os neurónios e quando estes não estão ligados assume o valor zero. Assim como no caso biológico, também nas redes neuronais artificiais há dois tipos de sinapses: as excitadoras e as inibidoras. Uma sinapse excitadora tem o seu peso positivo,  $w_i > 0$ , e uma sinapse inibidora tem o seu peso negativo,  $w_i < 0$  (Bittencourt, 2006). A soma das entradas  $x_i$ , ponderadas pelos pesos correspondentes  $w_i$  chama-se saída linear ou função de transferência  $u$ , onde  $u = \sum_{i=1}^n w_i x_i$ . A saída  $y$  do neurónio é obtida pela aplicação de uma função de activação  $f(\cdot)$  à saída linear  $u$ , indicada por  $y = f(u)$  (Braga *et al.*, 2003).

Figura 2: Estrutura de um neurónio artificial de McCulloch e Pitts



Fonte: Braga *et al.* (2003: 143)

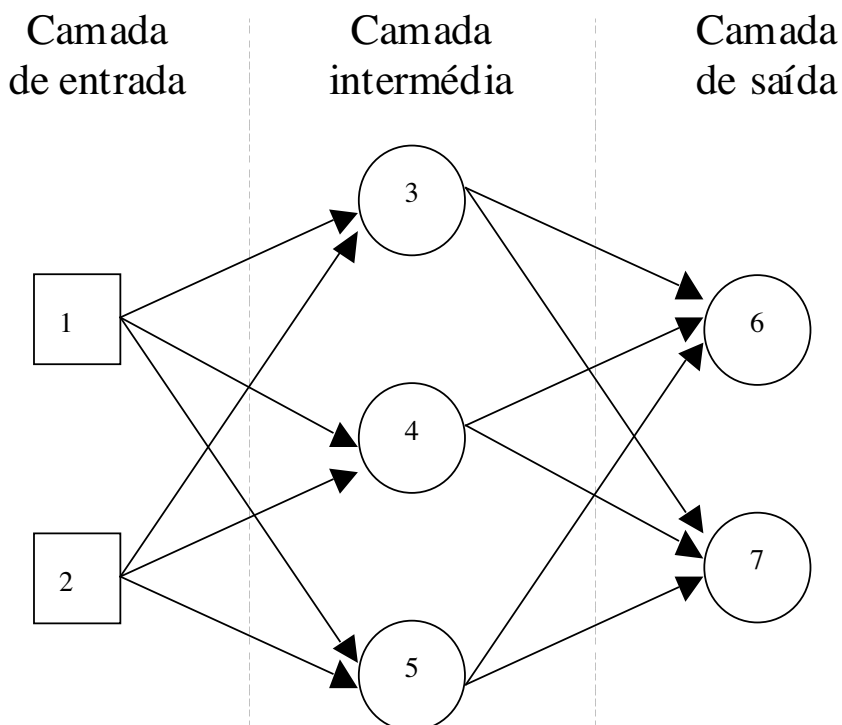
Existem diversos modelos neuronais e todos eles se inspiram em maior ou menor grau no funcionamento biológico do sistema nervoso. Os diferentes modelos são determinados pelas seguintes características diferenciadoras (Crespo, 2000):

- Tipo de neurónios, que, por sua vez, são definidos por:
  - Tipos de entrada que admite: binárias ou contínuas.
  - Valores dos parâmetros da função de transferência.

- Tipo de função de transferência: linear, sigmóide ou tangente hiperbólica.
- Arquitectura da rede, isto é, distribuição espacial dos neurónios.
- Leis de aprendizagem aplicadas: supervisionada ou não supervisionada.

As *Redes Feedforward Multicamada* (Figura 3), constituem uma das mais importantes e populares classes de redes neuronais artificiais, sendo utilizadas em múltiplos domínios de aplicação, nomeadamente, em problemas de memória associativa, classificação, reconhecimento de padrões, optimização e regressão. Estas redes caracterizam-se por possuir uma ou mais camadas ocultas em que a informação flui numa única direcção, isto é, desde a camada de entrada para as camadas ocultas e destas para a camada de saída. A não linearidade, a existência de neurónios intermédios e o alto grau de conectividade tornam esta arquitectura muito interessante como máquina de aprendizagem. O sinal de entrada propaga-se para a frente através da rede, camada por camada, não existindo ciclos (Quintela, 2005).

Figura 3: Estrutura de uma *Red Feedforward Multicamada*



Fonte: Cortez (2002)



Uma das propriedades das redes neuronais artificiais é a sua capacidade de aprendizagem e generalização. Inicialmente, uma rede neuronal artificial não dispõe, por si só, de conhecimento que possa determinar valores ou induzir o que quer que seja, uma vez que é apenas uma estrutura ou um modelo matemático-informático com capacidade de aprendizagem, sendo por isso necessário treiná-la ou ensiná-la (Crespo, 2000).

A aprendizagem pode ser supervisionada ou não supervisionada. Na aprendizagem supervisionada, indica-se qual é a variável de saída e consiste em introduzir na rede tanto as variáveis (ou dados) de entrada como a variável ou variáveis (dados) de saída. Deste modo, a rede terá que associá-los através de uma regra de aprendizagem. Ao longo do processo de aprendizagem é efectuada uma comparação entre o valor desejado com o valor de saída da rede, originando um erro. O erro é utilizado para ajustar os pesos das conexões, com o objectivo de o reduzir. A aprendizagem é alcançada quando o erro é minimizado (Quintela, 2005).

A aprendizagem não supervisionada segue uma abordagem diferente, e caracteriza-se por introduzir na rede apenas as variáveis (ou dados) de entrada sem pré-definir nenhum tipo de saída, o que implica que a rede terá que extrair da informação disponível as suas características essenciais (Crespo, 2000).

Uma vez finalizada a aprendizagem, isto é, estabelecida a estrutura e os correspondentes pesos sinápticos, a rede neuronal está preparada para entrar em funcionamento (Núñez, 1997).

## **Indução de regras e árvores de decisão**

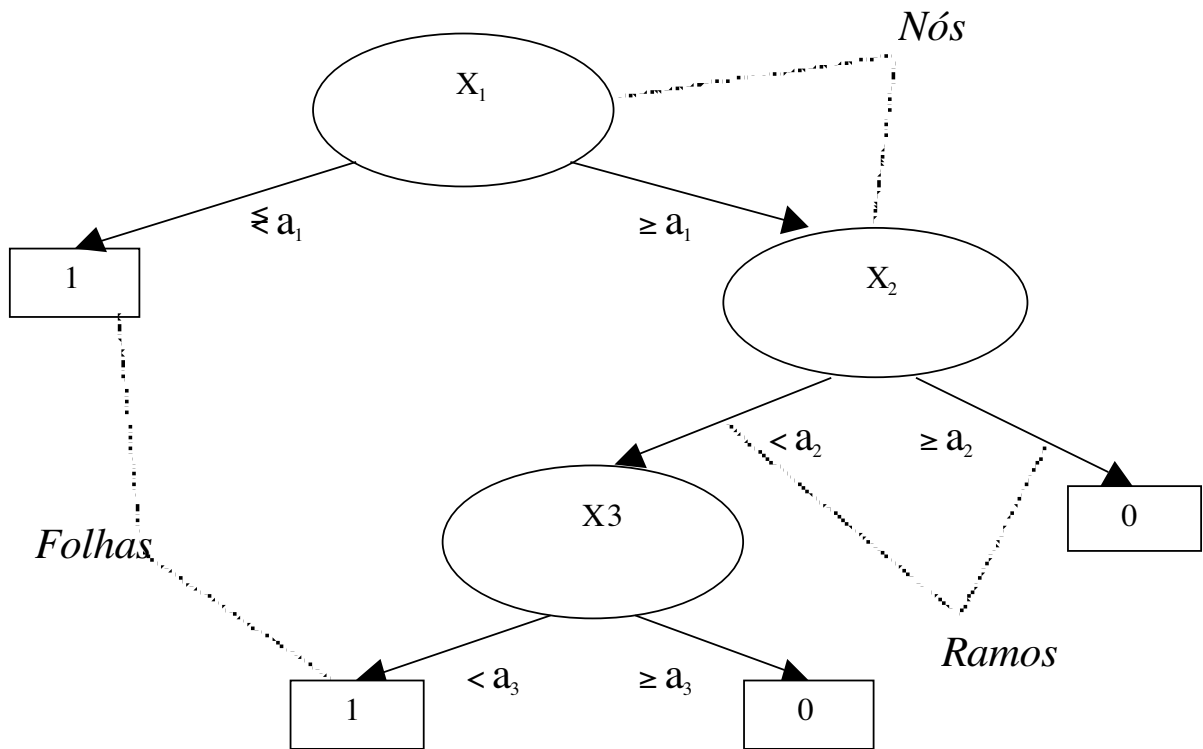
Estas técnicas constituem o outro grande conjunto de procedimentos de aprendizagem automática, além das redes neuronais artificiais. Dado que o seu desenvolvimento é mais recente, não se encontram tão generalizadas no mundo profissional como as redes. No entanto, têm despertado grande interesse no mundo académico.

Um dos principais contributos para o desenvolvimento das árvores de decisão deve-se a Quinlan (1983). Foi este autor que desenvolveu a tecnologia que permitiu o seu aparecimento, através do algoritmo ID3 (*Iterative Dichotomizer – Dicotomizador Iterativo*), o qual, a partir de um conjunto de dados de um exemplo permite construir automaticamente uma árvore de decisão.

As árvores de decisão são uma forma de representação de um conjunto de regras que seguem uma hierarquia de classes ou valores, expressando uma lógica simples condicional. Em termos gráficos podem ser semelhantes a uma árvore, consistindo numa estrutura que interliga um conjunto de nós através de *ramos* resultantes de

uma partição recursiva dos dados, desde o nó *raiz* até aos nós terminais (*folhas*), que fornecem a classificação para a instância, como se pode verificar na Figura 4.

Figura 4: Exemplo de uma árvore de decisão



Fonte: Elaboração própria

Os algoritmos de indução de árvores de decisão constroem os padrões a partir dos dados de treino, de uma forma recursiva efectuando a subdivisão do conjunto de dados até que este seja apenas composto por nós “puros”, isto é, sempre que possível tentar que cada nó represente apenas uma única classe ou satisfaça um determinado critério (Quintela, 2005).

Como podemos visualizar através da Figura 4, a estrutura das árvores geradas é formada por:

- folhas (nós puros) que correspondem às classes/objectos.
- nós internos que correspondem aos atributos (especifica algum teste efectuado num único atributo, com duas ou mais sub-árvores que representam saídas possíveis).

– ramos que correspondem aos valores dos atributos.

A indução de regras aparece muitas vezes associada às árvores de decisão, sendo usadas para expressar o conhecimento representado nestas. Uma vez que uma árvore de decisão se encontra na forma normal disjuntiva é relativamente fácil traduzir este classificador para um conjunto de regras de decisão. A apresentação das regras é efectuada tendo em consideração a seguinte prioridade: a regra mais importante é representada na árvore como o primeiro nó, seguindo-se as restantes regras de acordo com o seu grau de relevância ou prioridade.

Para Fayyad *et al.* (1996) a indução de regras corresponde ao processo de descoberta de padrões numa série de dados, consistindo na descoberta de regras de previsão do tipo *IF ... THEN*, onde *IF*, a “condição” da regra especifica alguns atributos e *THEN*, a “acção” da regra prevê um valor para um determinado atributo.

A partir da árvore de decisão da Figura 4 é possível extrair um conjunto de regras representativas do modelo através da técnica de indução de regras, como podemos demonstrar com recurso às seguintes regras que lhe estão associadas:

Tabela 5: Regras associadas à Figura 4

<p>Regra # 1</p> <p>IF <math>X1 &lt; a_1</math> THEN 1</p>	<p>Regra # 2</p> <p>IF <math>X1 \geq a_1</math> AND <math>X2 \geq a_2</math> THEN 0</p>
<p>Regra # 3</p> <p>IF <math>X1 \geq a_1</math> AND <math>X2 &lt; a_2</math> AND <math>X3 \geq a_3</math> THEN 0</p>	<p>Regra # 4</p> <p>IF <math>X1 \geq a_1</math> AND <math>X2 &lt; a_2</math> AND <math>X3 &lt; a_3</math> THEN 1</p>

Fonte: Elaboração própria

## 6.2 Vantagens e limitações de cada uma das técnicas

### Análise discriminante

Foram vários os autores que se referiram às limitações da análise discriminante quando aplicada em estudos sobre previsão de fracasso (Eisenbeis, 1977; Pinches, 1980; Mora, 1996; Sung *et al.*, 1999, entre outros).

As principais limitações relacionam-se com a distribuição das variáveis, a dispersão da matriz de covariâncias, a determinação da significância individual das variáveis, os erros de classificação, a redução da dimensão e a aplicação dos modelos *a priori*. A seguir abordaremos cada um dos referidos aspectos.

A distribuição das variáveis utilizadas deveria ser normal multivariada para que a análise discriminante funcionasse perfeitamente. No entanto, como afirma Eisenbeis (1977) na prática os desvios à distribuição normal, pelo menos na área económica e financeira são mais a regra que a excepção.

A utilização de funções lineares supõe uma igualdade das matrizes de covariâncias que indicam o grau de dispersão dos grupos. Se tal igualdade não se verifica, então, segundo Eisenbeis (1977) é preferível utilizar funções quadráticas. Também Keasey & Watson (1991: 91) referem que “a análise discriminante linear é teoricamente mais apropriada quando a matriz de variância-covariância das variáveis é igual para os grupos de empresas fracassadas e não fracassadas, enquanto que a análise discriminante quadrática é mais adequada quando a matriz para os dois grupos é distinta”. Na opinião de Marks & Dunn (1974) o comportamento da análise quadrática para matrizes distintas declina quando o tamanho da amostra é pequeno e o número de variáveis explicativas é grande em relação ao tamanho da amostra.

A determinação da significância das variáveis do modelo não é tarefa fácil, uma vez que não existe um teste para detectar o impacto absoluto de uma determinada variável. De acordo com Eisenbeis (1977) foram propostos alguns métodos na tentativa de determinar a importância relativa das variáveis, tais como o teste F de Snedecor à escala univariada e o ajuste dos coeficientes da função discriminante ao multiplicá-los pela diagonal da matriz de covariâncias correspondente. O autor acrescentou que estes métodos também apresentam limitações.

Quando se reduz a dimensão de um modelo eliminando algumas variáveis que aparentemente não são significativas poder-se-á afectar os resultados da classificação (Eisenbeis, 1977).

As regras de classificação devem incorporar os custos relativos dos erros e as probabilidades *a priori* de fracasso e não fracasso (Eisenbeis, 1977). Na prática constata-se que a maioria dos autores não tiveram em consideração esses aspectos.

Uma outra limitação relaciona-se com a aplicação dos modelos à priori. Há estudos que elaboram um modelo para cada ano antes do fracasso, o qual permite incrementar a capacidade predictiva dos modelos à posteriori. Como afirma Mora (1996) o problema coloca-se quando se pretende aplicar esses modelos à priori com o intuito de prever um possível futuro fracasso de uma empresa em actividade, dado que desconhecemos o ano prévio em que se encontra a empresa de tal possível desfecho.

Apesar das limitações metodológicas de muitos dos trabalhos que utilizaram a análise discriminante, esse facto não invalida os bons resultados que alcançaram com os seus estudos.

Entre as vantagens da análise discriminante podemos referir a sua capacidade para incorporar múltiplos rácios financeiros simultaneamente, bem como a sua capacidade de combinar variáveis independentes (Sung *et al.*, 1999). Outra vantagem deste método é que, uma vez desenvolvido o modelo, a sua aplicação é muito simples.

### **Modelo Logit**

Como refere Mora (1996) ao modelo *logit* também se aplicam algumas das limitações mencionadas para a análise discriminante, nomeadamente, a não consideração das probabilidades prévias e dos erros de classificação<sup>8</sup>, sempre que se utilize como ponto de corte 0,5 e também a aplicação dos modelos à priori.

Uma das vantagens deste modelo prende-se com o facto de admitir que as variáveis independentes possam ser categóricas, permitindo que as variáveis explicativas não se reduzam unicamente a rácios económicos e financeiros ou variáveis métricas, possibilitando desta forma a utilização de informação não financeira ou qualitativa (Ferrando & Blanco, 1998).

Para Lo (1986) o modelo *logit* é mais robusto que a análise discriminante, já que é aplicável a outras distribuições que não a normal.

Em comparação com o modelo *probit*, o *logit* tem representação e tratamento matemático mais simples, justificando a sua maior utilização prática.

---

<sup>8</sup> O mesmo ocorre nos restantes modelos.

## Modelo Probit

À semelhança do que sucede com o *logit*, o modelo *probit* apresenta bons resultados<sup>9</sup> no estudo do comportamento individual dos elementos de determinada população quando a variável dependente é binária ou dicotómica (Borooah, 2002).

Em termos práticos com o modelo *probit* obtêm-se as mesmas conclusões<sup>10</sup> que com o *logit*, tendo a desvantagem dos coeficientes *probit* serem mais difíceis de interpretar, por isso a sua menor utilização. Uma vez que tem por base uma curva normal padrão, o *probit* não é recomendado quando existirem muitos casos assimétricos ou com outra distribuição que não a normal (Pampel, 2000).

## Redes neuronais

As principais vantagens das redes neuronais artificiais resultam das suas próprias propriedades, destacando-se as seguintes:

- Aprendizagem e generalização. O sistema vai modificando o seu comportamento para o ajustar aos dados que se lhe introduzem, tentando descrever o todo a partir de algumas partes, constituindo-se como formas eficientes de aprendizagem e armazenamento de conhecimento (Cortez, 1997).

- Processamento massivo paralelo. Permite que tarefas complexas sejam realizadas num curto espaço de tempo, uma vez que cada neurónio pode calcular uma função elementar sem necessidade de cooperar com os demais.

- Adaptabilidade. Embora a aprendizagem da rede se tenha realizado num momento inicial com um determinado número de casos, é sempre possível treinar novamente a rede incorporando ao conjunto de dados novas situações resultantes, por exemplo, de informação que não se dispunha no momento inicial (De Andrés, 2000).

- Robustez e degradação suave. Permite processar o ruído ou a informação incompleta de forma eficiente, sendo capazes de manter o seu desempenho mesmo quando ocorre a desactivação de algumas conexões ou neurónios (Quintela, 2005).

- Não linearidade. É possível a modelação não linear dos dados, o que também é uma virtude, dado que a maioria dos problemas reais são de natureza não linear (Cortez, 2002).

---

<sup>9</sup>O autor refere-se aos diversos campos de investigação, e não especificamente sobre a previsão da insolvência.

<sup>10</sup>Segundo Borooah (2002) para os mesmos dados, com a análise *logit* e *probit* geralmente obtêm-se a mesma conclusão, no entanto os coeficientes diferem em magnitude.

No entanto, as redes neuronais também apresentam inconvenientes. O mais referido é a dificuldade de analisar o seu processo de raciocínio. Estes sistemas podem ser entendidos como modelos de “caixa negra” que dão respostas, mas não transmitem conhecimento sobre o processo que conduziu à obtenção das mesmas. Outra limitação ocorre, principalmente, quando não existe um adequado número de casos para treino, uma vez que após um determinado número de iterações, o desempenho da rede começa a piorar para os casos de teste, não obstante continuar a melhorar para os casos de treino (Cortez, 2002). Como já referimos, este problema designa-se por *overfitting* (*sobre-ajustamento*).

### **Indução de regras e árvores de decisão**

As árvores de decisão apresentam como vantagens a sua versatilidade e um elevado índice de legibilidade e compreensão que permitem identificar de forma expedita os factores mais influentes. A principal desvantagem advém da necessidade de se utilizar uma quantidade considerável de dados quando se trata de estruturas complexas (Quintela, 2005).

Algumas das vantagens da indução de regras revelam-se pelo desempenho, facilidade de explicação e compreensibilidade, fácil identificação dos passos para a solução do problema e no pouco espaço de armazenamento.

O facto das regras serem altamente heurísticas, a dificuldade de manuseamento da informação incompleta ou valores inesperados e o processo para induzir regras ser mais lento que para induzir árvores de decisão constituem as principais desvantagens desta técnica (Monard, 2003).

### **6.3 As ferramentas disponíveis**

Actualmente, existem no mercado de sistemas operativos as mais diversas soluções, que têm registado constantes evoluções ao nível do *software*, fruto de novas tecnologias e da necessidade de maiores capacidades de processamento da informação.

A quase totalidade das ferramentas disponíveis têm sido desenvolvidas com finalidades comerciais. No entanto, também há *softwares* desenvolvidos por motivos académicos.

Uma característica a considerar em todos os *softwares* é o tipo de licenciamento para ser possível a sua utilização. Os tipos de licenciamento variam de acordo com

os objectivos da entidade que desenvolveu o *software*, e passam pelas aplicações públicas<sup>11</sup>, de uso e modificação livre até às aplicações comerciais. Enquanto os licenciamentos do tipo público têm por objectivo a divulgação e promoção de um *software*, os de tipo comerciais procuram o lucro.

Na tabela 2 são apresentadas algumas das ferramentas que poderão ser utilizadas na previsão do fracasso empresarial, referindo o tipo de licenciamento (C = comercial; P = público) e o tipo de desenvolvimento (C = comercial; A= académico ou investigação).

Tabela 2 – Tipo de licenciamento e desenvolvimento das ferramentas

<b>Ferramenta</b>	<b>Tipo de licença</b>	<b>Tipo de desenvolvimento</b>
BrainMaker	C	C
C 5.0	C	C
CART	C	C
Clementine	C	C
Matab	C	C
NeuralWare	C	C
NeuralWorks	C	C
NeuroShell	C	C
NeuroSolutions	C	C
SAS Enterprise Miner	C	C
See 5	C	C
SPSS	C	C
Weka	P	A
XpertRule	C	C

Fonte: Adaptado de Santos & Azevedo (2005)

Muitos dos estudos<sup>12</sup> de previsão do fracasso que recorrem a técnicas estatísticas utilizaram o SPSS (Dambolena & Khoury, 1980; Ferrando & Blanco, 1998; Charitou *et al.*, 2004) ou o SAS (Lane *et al.*, 1986; Gilbert *et al.*, 1990; Laitinen, 1991;

<sup>11</sup> As ferramentas de uso público são as que normalmente estão associadas a licenças como a GNU (*General Public License*).

<sup>12</sup> Nem todos os estudos fazem referência ao *software* utilizado.



Ward, 1994; Zhang *et al.*, 1999; Sung *et al.*, 1999; Grice & Dugan, 2001; Galindo & Drozdowskyj, 2002).

Para as técnicas de *data mining* existe uma variada gama de ferramentas. Por exemplo, (Salchenberger *et al.*, 1992; Coats & Fant, 1993; Fanning & Cogger, 1994) utilizaram o NeuralWorks. O Brainmaker foi usado por (Wilson & Sharda, 1994; Barniv *et al.*, 1997). O NeuroShell foi utilizado por (Odom & Sharda, 1990; Fletcher & Goss, 1993). Rodríguez (2002) utilizou o NeuroSolutions<sup>13</sup>. Tam & Kiang (1992) e Mckee & Greenstein (2000) usaram o ID3, Kotsiantis *et al.* (2005) o C4.5, Cielen, (2004) o C5.0 e González *et al.* (1999) o *See 5*.

Na tabela 3 podemos ver uma relação das ferramentas referidas na tabela anterior com as suas potenciais aplicações para as distintas técnicas.

Tabela 3 – Potencialidades aplicativas das ferramentas

<b>Técnicas</b>	<b>Análise</b>	<b>Logit</b>	<b>Probit</b>	<b>Redes</b>	<b>Indução</b>
<b>Ferramentas</b>	<b>Discriminante</b>			<b>Neuronais</b>	<b>de</b>
					<b>Regras</b>
					<b>Árvores</b>
					<b>Decisão</b>
BrainMaker				X	
C 5.0					X
CART					X
Clementine				X	X
NeuralWare				X	
NeuralWorks				X	
NeuroShell				X	
NeuroSolutions				X	
SAS Ent. Miner		X		X	X
See 5					X
SPSS	X	X	X	X	
Weka				X	
XpertRule					X

Fonte: Elaboração própria

<sup>13</sup> Ramamoorti *et al.* (1999) treinaram uma rede tendo utilizado três *softwares* diferentes: NeuroShell, NeuralWare e NeuroSolutions, tendo obtido melhores resultados com o programa NeuralWare.

#### 6.4. Funcionalidades dos modelos

De uma forma natural e lógica, os dirigentes das empresas são os primeiros a detectar uma potencial situação de perigo ou fracasso, mas também é verdade que, ao fazerem parte do sistema podem adoptar comportamentos tendentes a ocultar tal situação. Por isso, e para que os diversos utilizadores tenham possibilidades de obter informação adicional que ajude na tomada de decisões, tornam-se particularmente úteis sistemas de alerta que permitam aos mesmos tentar prever o fracasso empresarial.

Os modelos de previsão do fracasso empresarial que utilizam a informação contabilística publicada pelas empresas têm a vocação de ser instrumentos ao serviço de tais sistemas de alerta (Galindo & Drozdowskyj, 2002). Para que estes sistemas sejam úteis devem ser fiáveis, práticos e acessíveis.

Na maioria dos estudos e independentemente da técnica utilizada as percentagens de precisão<sup>14</sup> dos modelos, pelo menos no ano prévio ao fracasso, podem-se considerar muito animadoras.

Para um utilizador comum, tanto na elaboração de um modelo como na aplicação a uma situação em concreto utilizando um modelo previamente elaborado, parece-nos que os métodos que utilizam técnicas estatísticas se apresentam como os mais práticos e fáceis de aplicar. Se o intuito é o desenvolvimento de um modelo utilizando técnicas de *data mining* a tarefa revela-se mais complicada uma vez que estas ainda estão pouco divulgadas, sendo reduzido o número de pessoas que estão familiarizadas e que possuem os conhecimentos e as ferramentas necessárias à sua aplicação. No entanto, se o objectivo é simplesmente utilizar um modelo previamente elaborado a dificuldade reside essencialmente nos modelos de redes neuronais, pelos motivos já referidos, sendo a utilização dos modelos obtidos com as restantes técnicas mais acessíveis.

Para os utilizadores institucionais, como as empresas de *rating* ou instituições financeiras e de crédito, provavelmente não terão dificuldades em utilizar qualquer dos métodos, uma vez que possuem capacidades para recrutar os especialistas e adquirir a tecnologia que lhes permita elaborar e utilizar os modelos que entendam ser mais apropriados para lhes facultar as informações de suporte às decisões.

#### 7. Amplitude dos resultados obtidos

Segundo (Laffarga, 1999:31) “a maioria dos estudos realizados para prever a insolvência empresarial obtêm modelos cuja capacidade predictiva oscila entre 70% e 99% de acertos na previsão da insolvência das empresas.”

---

<sup>14</sup> Considerando os estudos publicados e que analisamos.

Partindo dos dados sobre variados estudos, elaboramos uma relação onde fazemos referência a cada um dos modelos que estamos a analisar neste trabalho, e que nos permite comprovar que a capacidade predictiva de cada um deles geralmente oscila entre o referido intervalo, como podemos visualizar na tabela 4.

Podemos concluir que nenhum dos modelos é claramente superior aos restantes. No entanto, devemos ter cuidado ao efectuarmos a comparação dos resultados, dado que as definições de fracasso consideradas não eram todas iguais, a dimensão das amostras, o tipo de empresas, o sector de actividade e o período considerado para análise também eram diferentes, e todos estes factores são susceptíveis de condicionar o resultado final.

Tabela 4: Resumo das principais características de alguns trabalhos

Autor	Técnica	Dimensão Amostra		Sector	Período	Número Variáv.	(%)
		F	NF				
DEAKIN (1972)	AD	32	32	I	1962-1966	14	97,00
BLUM (1974)	AD	115	115	I	1954-1968	12	94,00
DAMBOLENA & KHOURY (1980)	AD	23	23	I/C	1969-1975	19	94,40
ALY ET AL. (1992)	AD	26	26	I	1979-1987	14	73,10
OHLSON (1980)	L	105	2058	I	1970-1976	9	96,12
ZAVGREN (1985)	L	45	45	I	1972-1978	7	82,00
GENTRY ET AL. (1985)	L	33	33	I	1970-1981	12	83,33
PLAT & PLAT (1990)	L	57	57	I/C	1972-1987	26	90,00
TENNYSON ET AL. (1990)	L	23	23	I	1978-1980	5	76,00
GILBERT ET AL. (1990)	L	52	208	I	1974-1983	14	88,50
WARD (1994)	L	14	37	I	1988-1989	7	88,20
PLAT ET AL. (1994)	L	35	89	I	1982-1988	12	90,30
ZMIJEWSKI (1984)	P	40	800	I	1972-1978	3	71,70
GENTRY ET AL. (1987)	P	33	33	I	1970-1981	12	83,00
DE ANDRÉS (2005)	P	29	37	B	1977-1982	9	90,00
COATS & FANT (1993)	RN	94	188	I/C/S	1970-1989	5	95,00
TAM & KIANG (1992)	RN	118	118	B		19	92,00
SUNG ET AL. (1999)	IRAD	29	49	I	N <sup>15</sup>	40	83,30
		30	54				C

AD: Análise Discriminante; L: *Logit*; P: *Probit*; RN: Redes Neurais; IRAD: Indução Regras Árvores de Decisão; I: Indústria; C: Comércio; S: Serviços; B: Banca.

Fonte: Elaboração própria

<sup>15</sup>N: Sob condições económicas “normais” (1991-95). C: Sob uma situação de crise económica (1997-98)

## 8. Conclusão

Pelo que referimos podemos concluir que existe um elevado grau de heterogeneidade entre os diferentes estudos, fruto da utilização de distintos conceitos de fracasso, amostras seleccionadas, técnicas utilizadas e número e tipo de variáveis seleccionadas. Este facto sucede devido à ausência de uma teoria geral do fracasso empresarial, que permite que os aspectos acabados de referir sejam escolhidos e decididos pelos próprios autores ou em função da disponibilidade dos dados.

São várias as técnicas existentes, todas elas apresentam vantagens e limitações, porém não existe acordo sobre qual é a óptima. A selecção das variáveis independentes em determinados estudos tem sido efectuada com a ajuda de técnicas econométricas, noutros essa selecção baseou-se no desempenho apresentado por tais variáveis em estudos prévios, ou como referem alguns investigadores, as mesmas podem até depender da disponibilidade dos dados. As referidas variáveis apresentam como principal problema metodológico o incumprimento dos requisitos estatísticos que exigem algumas das técnicas.

Sobre a variável dependente o principal problema coloca-se na definição de fracasso empresarial, que, como também vimos nem sempre é coincidente.

Também constatamos que existe uma diversidade de ferramentas disponíveis no mercado para estimar os modelos predictivos, quase todas de natureza comercial. No entanto, os elevados preços da maioria fazem com que apenas as instituições com elevada capacidade financeira ou os centros de investigação tenham possibilidades para as adquirir ou suportar as respectivas licenças.

Verificamos que as técnicas mais populares na literatura sobre previsão de insolvência são a análise discriminante e o *logit* (dentro das técnicas estatísticas) e as redes neuronais (dentro das técnicas de *data mining*). Na óptica do simples utilizador as técnicas estatísticas, bem como as técnicas cujos modelos obtidos vêm expressos sob a forma de regras ou árvores de decisão são as mais práticas e acessíveis, ao contrário das redes neuronais.

Na óptica da elaboração dos modelos, as técnicas estatísticas são também as mais acessíveis, sendo que a maioria das ferramentas de *data mining* apresentam ainda ambientes ou interfaces complicados, pouco atractivos e outros não divulgam a forma como foi gerado o conhecimento.

Para concluir podemos dizer que o desenvolvimento deste tipo de estudos, alguns utilizando metodologias com um nível de sofisticação cada vez maior, permitem acumular evidência empírica que irá certamente contribuir para a formulação de uma teoria geral do fracasso empresarial.

## Bibliografia

- Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23(4), 589-609.
- Altman, E. I., Marco, G. & Varetto, F. (1994). Corporate Distress Diagnosis: Comparisons Using Linear Discriminant Analysis and Neural Networks (The Italian Experience). *Journal of Banking and Finance*, 18, 505-529.
- Aly, I. M.; Barlow, H. A. & Jones, R. W. (1992). The Usefulness of SFAS N.º 82 (Current Cost) Information in Discriminating Business Failure: An Empirical Study. *Journal of Accounting, Auditing and Finance*, 7(2), 217-229.
- Aziz, A. & Lawson, G. (1989). Cash Flow Reporting and Financial Distress Modeling: Testing of Hypothesis. *Financial Management*, 1(2), 55-63.
- Baldwin, J. & Glezen, G. W. (1992). Bankruptcy Prediction Using Quarterly Financial Statement Data. *Journal of Accounting, Auditing and Finance*, 7(2), 269-285.
- Barniv, R.; Agarwal, A. & Leach, R. (1997). Predicting the Outcome Following Bankruptcy Filing: a Three-State Classification Using Neural Networks. *International Journal of Intelligent Systems in Accounting, Finance and Management*, 6(3), 177-194.
- Baum, E. B. & Haussler, D. (1989). *What Size Net Give Valid Generalization*, in Neural Computation 1, MIT Press: Cambridge, MA, 151-160.
- Beaver, W. H. (1966). Financial Ratios as Predictors of Failure. *Journal of Accounting Research*, 4, 71-111.
- Benishay, H. (1971). Economic Information in Financial Ratio Analysis. *Accounting and Business Research*, Spring, 174-179.
- Berry, M. J. A. & Linoff, G. (2000). *Mastering Data Mining: The Art and Science of Customer Relationship Management*. John Wiley & Sons, Inc.: USA.
- Bhargava, M.; Dubelaar, C. & Scott, T. (1998). Predicting Bankruptcy in the Retail Sector: An Examination of the Validity of Key Measures of Performance. *Journal of Retailing and Consumer Services*, 5 (2), 105-117.

- Bittencourt, G. (2006). *Inteligência Artificial: Ferramentas e Teorias*. Editora da Universidade Federal de Santa Catarina: Florianópolis, Brasil.
- Blum, M. (1974). Failing Company Discriminant Analysis. *Journal of Accounting Research*, 12(1), 1-25.
- Boritz, E.; Kennedy, D. & Albuquerque, A. (1995). Predicting Corporate Failure Using a Neural Network Approach. *Internacional Journal of Intelligent Systems in Accounting, Finance & Management*, 4(2), 95-112.
- Borooah, V. K. (2002). *Logit and Probit: Ordered and Multinomial Models*. Quantitative Applications in the Social Sciences, Series N.º 138, Sage Publications: Thousand Oaks, California.
- Braga, A. P., Carvalho, A. C. F. & Ludermir, T. B. (2003). Redes Neurais Artificiais. In S. O. Rezende (Ed.), *Sistemas Inteligentes: Fundamentos e Aplicações* (141-168). São Paulo: Editora Manole.
- Charitou, A., Neophytou, E. & Charalambous, C. (2004). Predicting Corporate Failure: Empirical Evidence for the UK. *European Accounting Review*, 13(3), 465-497.
- Cielen, A., Peeters, L. & Vanhoof, K. (2004). Bankruptcy Prediction using a Data Envelopment Analysis. *European Journal of Operational Research*, 154, 526-532.
- Coats, P. K. & Fant, L. F. (1993). Recognizing Financial Distress Patterns Using a Neural Network Tool. *Financial Management*, 22(3), 142-155.
- Cortez, P. A. R. (2002). *Modelos Inspirados na Natureza para a Previsão de Séries Temporais*. Tese de Doutoramento, Universidade do Minho.
- Cortez, P. A. R. (1997). *Algoritmos Genéticos e Redes Neurais na Previsão de Séries Temporais*. Dissertação de Mestrado, Universidade do Minho.
- Crespo, M. Á. D. (2000). *Análisis de los Factores Explicativos del Fracaso Empresarial en Galicia: Un Análisis Empírico Mediante la Utilización de Modelos de Redes Neuronales*. Vigo: Edição Própria.
- Dambolena, I. G. & Khoury, S. J. (1980). Ratio Stability and Corporate Failure. *The Journal of Finance*, 35(4), 1107-1126.

- De Andrés, J. S. (2005). Comparativa de Métodos de Predicción de la Quiebra: Redes Neuronales Artificiales vs. Métodos Estadísticos Multivariantes. *Partida Doble*, 168, 104-113.
- De Andrés, J. S. (2000). *Técnicas de Inteligencia Artificial Aplicadas al Análisis de la Solvencia Empresarial*. Documento de trabajo 206/00, Universidad de Oviedo.
- Deakin, E. B. (1972). A Discriminant Analysis of Predictors of Business Failure. *Journal of Accounting Research*, 10 (1), 167-179.
- Eidleman, G. J. (1995). Z Scores – A Guide to Failure Prediction. *CPA Journal*, 65(2), 52-54.
- Eisenbeis, R. A. (1977). Pitfalls in the Application of Discriminant Analysis in Business, Finance, and Economics. *The Journal of Finance*, 32(3), 875-900.
- Elam, R. (1975). The Effect of Lease Data on the Predictive Ability of Financial Ratios. *The Accounting Review*, 50(1), 25-43.
- Fanning, K. M. & Cogger, K. O. (1994). A Comparative Analysis of Artificial Neural Networks Using Financial Distress Prediction. *Internacional Journal of Intelligent Systems in Accounting, Finance & Management*, 3(3), 241-252.
- Fayyad, U., Piatetsky-Shapiro, G. & Smyth, P. (1996). The KDD Process for Extracting Useful Knowledge From Volumes of Data. *Communications of the ACM*, 39(11), 27-34.
- Fernández, E., Montes, J. M. & Vázquez, C. J. (1996). Caracterización Económico-Financiera de la Gran Empresa Industrial Española según su Rentabilidad. *Revista Española de Financiación y Contabilidad*, 25(87), 343-359.
- Ferrando, M. B. & Blanco, F. R. (1998). La Previsión del Fracaso Empresarial en la Comunidad valenciana: Aplicación de los Modelos Discriminante y Logit. *Revista Española de Financiación y Contabilidad*, 27(95), 499-540.
- Fletcher, D. & Goss, E. (1993). Forecasting with Neural Networks: An Application Using Bankruptcy Data, *Information & Management*, 24, 159-167.
- Flexer, A. (1996). *Statistical Evaluation of neural Network Experiments: Minimum Requirements and Current Practice*. In Proceedings of the 13th European Meeting on Cybernetics and Systems Research (pp.1005-1008), Vienna.

- Frank, W. (1969). A Study of the Predictive Significance of Two Income Measures. *Journal of Accounting Research*, 7(1), 123-136.
- Frydman, H., Altman, E. I. & Kao, D.-L. (1985). Introducing Recursive Partitioning for Financial Classification: The Case of Financial Distress. *The Journal of Finance*, 40(1), 269-291.
- Gabás, F. T. (1997). Predicción de la Insolvencia Empresarial. In A. S. Calvo-Flores & D. P. L. García (Eds.), *Predicción de la Insolvencia Empresarial*, (pp.11-31). Madrid: A.E.C.A.
- Galindo, R. D. & Drozdowskyi, A. (2002). Un Modelo de Predicción de Fracaso Empresarial. *Partida Doble*, 134, 60-67.
- Gallego, A. M. M., Gómez, J. C. S. & Yáñez, L. (1997). Modelos de Predicción de Quiebras en Empresas no Financieras. *Actualidad Financiera*, Mayo, 3-14.
- Gentry, J. A., Newbold, P. & Whitford, D. T. (1987). Funds Flow Components, Financial Ratios, and Bankruptcy. *Journal of Business Finance & Accounting*, 14(4), 595-606.
- Gentry, J. A., Newbold, P. & Whitford, D. T. (1985). Classifying Bankruptcy Firms with Funds Flow Components. *Journal of Accounting Research*, 23(1), 146-160.
- Gilbert, L. R., Menon, K. & Schwartz, K. B. (1990). Predicting Bankruptcy for Firms in Financial Distress. *Journal of Business Finance & Accounting*, 17(1), 161-171.
- González, A. L. P., Correa, A. R. & Blázquez, J. A. M. (1999). Perfil de Fracaso Empresarial para una Muestra de Pequeñas y Medianas Empresas. *X Congreso AECA*, Septiembre, Zaragoza.
- Grice, J. S. & Dugan, M. T. (2001). The Limitations of Bankruptcy Prediction Models: Some Cautions for the Researcher. *Review of Quantitative Finance and Accounting*, 17, 151-166.
- Hagan, M.T., Demuth, H. B. & Beale, M. (1996). *Neural Network Design*. PWS Publishing Company.
- Hair, J. F., Anderson, R. E., Tatham R. L. & Black, W. C. (1998). *Multivariate Data Análisis*, 5th ed. Prentice Hall.



- Hosmer D. W. & Lemeshow S. (1989). *Applied Logistic Regression*. John Wiley & Sons, Inc.: USA.
- Johnston, J. & DiNardo, J. (2001). *Métodos Econométricos*. 4.<sup>a</sup> Edição. Lisboa: McGraw-Hill.
- Keasey, K. & McGuinness, P. (1990). The Failure of UK Industrial Firms for the Period 1974-1976, Logistic Analysis and Entropy Measures. *Journal of Business Finance & Accounting*, 17(1),119-135.
- Keasey, K. & Watson, R. (1991). Financial Distress Prediction Models: A Review of Their Usefulness, *British Journal of Management*, 2, 89-102.
- Keasey, K. & Watson, R. (1987). Non-Financial Symptoms and the Prediction of Small Company Failure: A Test of Argenti's Hypotheses. *Journal of Business Finance & Accounting*, 14(3), 335-354.
- Kim, M. & Kim, M. (1999). A Note on the Determinants of the Outcomes of Bankruptcy Petitions: Evidence from Korea. *Journal of Business Finance & Accounting*, 26(7-8), 997-1011.
- Kleinbaum, D. G. (1996). *Logistic Regression: A Self-Learning Text*. New York: Springer-Verlag.
- Koh, H. C. & Tan, S. S. (1999). A Neural Network Approach to the Prediction of Going Concern Status. *Accounting and Business Research*, 29(3), 211-216.
- Kohavi, R. & Provost, F. (1998). Glossary of Terms. *Machine Learning*, 30(2-3), 271-274.
- Kotsiantis S., Tzelepis, D., Koumanakos, E. & Tampakas, V. (2005, July). *Efficiency of Machine Learning Techniques in Bankruptcy Prediction*. Paper presented at the 2nd International Conference on Enterprise Systems and Accounting, Thessaloniki, Greece.
- Laffarga, J. B. (1999). Los modelos de predicción de la insolvencia empresarial: limitaciones y utilidades. *Boletín AECA*, 48, 31-34.
- Laffarga, J. B. & Mora, A. E. (1998). Los Modelos de Predicción de la Insolvencia Empresarial: Un análisis Crítico. In A. S. Calvo-Flores & D. P. L. García (Eds.), *El Riesgo Financiero de la Empresa*, (pp.11-58). Madrid: A.E.C.A.

- Laffarga, J. B., Martín, J. & Vázquez, J. (1985). El Análisis de la Solvencia en las Instituciones Bancarias: Propuesta de una Metodología y Aplicaciones a la Banca Española. *ESIC Market*, 48, 51-73.
- Laitinen, E. K. (1991). Financial Ratios and Different Failure Processes. *Journal of Business Finance & Accounting*, 18(5), 649-673.
- Lane, W., Looney, S. & Wansley, J. (1986). An application of the Cox proportional hazards model to bank failure. *Journal of Banking and Finance*, 10, 511-531.
- Lev, B. (1978). *Análisis de los Estados Financieros: Un Nuevo Enfoque*. Madrid: Ediciones ESIC.
- Lizarraga, F. D. (1998). Modelos de Previsión del Fracaso Empresarial: Funciona entre nuestras Empresas el Modelo de Altman de 1968?. *Revista de Contabilidad*, 1(1), 137-164.
- Lizarraga, F. D. (1995). Información Contable y Fracaso Empresarial: Una Contratación de los Resultados Univariantes de Beaver con Datos del Registro Mercantil. *VIII Congreso AECA*, 601-618.
- Lo, A. W. (1986). Logit Versus Discriminant Analysis: a Specification Test and Application to Corporate Bankruptcy. *Journal of Econometrics*, 31, 151-178.
- López, D. H., Moreno, J. R. & Rodríguez, P. R. (1994). Modelos de Previsión del Fracaso Empresarial: Aplicación a Entidades de Seguros en España. *ESIC Market*, abril-junio, 83-125.
- Marks, S. & Dunn, D. (1974). Discriminant Functions when Covariance Matrices are Unequal. *Journal of the American Statistical Association*, June, 555-559.
- Martin, D. (1977). Early warning of bank failure: a logit regression approach. *Journal of Banking and Finance*, November, 249-276.
- McGurr, P. T. & DeVaney, S. A. (1998). Predicting Business Failure of Retail Firms: An Analysis Using Mixed Industry Models. *Journal of Business Research*, 43, 169-176.
- McKee, T. E. (1995). Predicting Bankruptcy via Induction. *Journal of Information Technology*, 10, 26-36.
- McKee, T. E. & Greenstein M. (2000). Predicting Bankruptcy Using Recursive Partitioning and a Realistically Proportioned Data Set. *Journal of Forecasting*, 19, 219-230.

- Messier, W. F. & Hansen, J. V. (1988). Inducing Rules for Expert System Development: An Example Using Default and Bankruptcy Data. *Management Science*, 34(12), 1403-1415.
- Monard, M. C. (2003). Indução de Regras e Árvores de Decisão. In S. O. Rezende (Ed.), *Sistemas Inteligentes: Fundamentos e Aplicações* (115-139). São Paulo: Editora Manole.
- Mora, A. E. (1996). *El Contenido Informativo de los Datos Contables para las Decisiones de Inversion*. Instituto de Contabilidad y Auditoría de Cuentas, Madrid.
- Mora, A. E. (1994). Los Modelos de Predicción del Fracaso Empresarial: Una aplicación Empírica del Logit. *Revista Española de Financiación y Contabilidad*, 23(78), 203-233.
- Nelson, F. D. (1990). Logit, Probit and Tobit. In *The New Palgrave: Econometrics*, 136-144.
- Núñez, C. G. (1997). *La Construcción de una Red Neuronal para el Análisis de Riesgos en las Entidades Financieras*. Tesis Doctoral, Universidad de Sevilla.
- O'Leary, D. E. (1998). Using Neural Networks to Predict Corporate Failure. *International Journal of Intelligent Systems in Accounting, Finance & Management*, 7, 187-197.
- Odom, M. & Sharda, R. (1990). A Neural Network Model for Bankruptcy Prediction. *Proceedings of the International Joint Conference on Neural Networks*, June, 163-168.
- Ohlson, J. S. (1980). Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, 19, 109-131.
- Pampel, F. C. (2000). *Logistic Regression: A Primer*. Quantitative Applications in the Social Sciences, Series N.º 132, Thousand Oaks: Sage Publications.
- Pina, V. (1989). La Información Contable en la Predicción de la Crisis Bancaria: 1977-1985. *Revista Española de Financiación y Contabilidad*, 18(58), 309-338.
- Pinches, G. E. (1980). Factors Influencing Classification Results From Multiple Discriminant Analysis. *Journal of Business Research*, 8, 429-456.

- Platt, H. D. & Platt, M. B. (1990). Development of a Class of Stable Predictive Variables: The Case of Bankruptcy Prediction. *Journal of Business, Finance & Accounting*, 17(1), 31-51.
- Platt, H. D., Platt, M. B. & Pedersen, J. G. (1994). Bankruptcy Discrimination with Real Variables. *Journal of Business, Finance & Accounting*, 21(4), 491-508.
- Quinlan, J. R. (1983). Learning Efficient Classification Procedures. In *Machine Learning: An Artificial Intelligence Approach*. Palo Alto: Tioga Press.
- Quintela, H. (2005): Sistemas de Conhecimento Baseados em Data Mining: Aplicação à Análise da Estabilidade de Estruturas Metálicas, Dissertação de Mestrado, Departamento de Sistemas de Informação, Universidade do Minho, Portugal.
- Ramamoorti, S., Bailey, A. D. & Traver, R. O. (1999). Risk Assessment in Internal Auditing: A Neural Network Approach. *International Journal of Intelligent Systems in Accounting, Finance & Management*, 8, 159-180.
- Reis, E. (1997). *Estatística Multivariada Aplicada*. Lisboa: Edições Sílabo.
- Renart, M. A. (2003). Revisión sobre la Evaluación del Riesgo de Fracaso Empresarial. Consideraciones y Propuestas Hacia el Consenso. In *Estudios Académicos de Contabilidad* (5-29), Universidad de Murcia.
- Rodríguez, J. M. F. (1989). Análisis de las Insolvencias Bancarias en España: un Modelo Empírico. *Moneda y Crédito*, 189, 187-227.
- Rodríguez, M. C. A. (1990). *La Predicción de las Crisis Empresariales. Modelos para el Sector de Seguros*. Universidad de Valladolid.
- Rodríguez, M. L. (2002). Modelos de Insolvencia en Empresas Gallegas. Aplicación de Técnicas Paramétricas y de Inteligencia Artificial. In F. T. Doldán & M. L. Rodríguez (Eds.), *La gestión del riesgo de crédito. Métodos y modelos de predicción de la insolvencia empresarial* (73-114). Madrid.
- Rodríguez, M. L. V. (1994). Utilidad del análisis de ratios para la predicción de la insolvencia empresarial. *Actualidad Financiera*, 34, 699-724.
- Román, I. M. & De La Torre, J. M. M. (2002). Una Visión Sectorial del Análisis del Riesgo de Insolvencia. Aplicación a la Situación de la Empresa Media Andaluza. In *Ensayos Científicos sobre Contabilidad* (677-685), Universidad de Málaga.

- Salchenberger, L., Cinar, E. & Lash, N. (1992). Neural Networks: A New Tool for Predicting Thrift Failures. *Decision Sciences*, 23(4), 899-916.
- Santomero, A. & Vinso, J. (1977). Estimating the Probability of Failure for Commercial Banks and the Banking System. *Journal of Banking and Finance*, 1(2), 185-205.
- Santos, M. F. & Azevedo, C. (2005). *Data Mining – Descoberta de Conhecimento em Base de Dados*. FCA: Lisboa.
- Scherr, F. C. (1989). Causality, Regression, Discriminant Analysis, and Research on Failure. *Akron Business and Economic Review*, 20(1), 8-20.
- Serrano, C. C. (1994). *Las Redes Neuronales Artificiales en el Análisis de la Información Contable*. Tesis Doctoral, Universidad de Zaragoza.
- Sinkey, J. F. (1975). A Multivariate Statistical Analysis of the Characteristics of Problem Banks. *The Journal of Finance*, 30(1), 21-36.
- Somoza, A. L. (2002). Modelos de Predicción de la Insolvencia: La Incorporación de outro Tipo de Variables”, In F. T. Doldán & M. L. Rodríguez (Eds.), *La gestión del riesgo de crédito. Métodos y modelos de predicción de la insolvencia empresarial* (pp.139-173). Madrid: A.E.C.A.
- Somoza, L. A. & Vallverdú, J. C. (2003). Un Modelo de Predicción de la Insolvencia Empresarial Basado en Variables Financieras. Su Aplicación al Caso Textil Catalán (1994-1997). *Revista de Contabilidad*, 6(11), 173-191.
- Sung, T. K., Chang, N. & Lee, G. (1999). Dynamics of Modeling in Data Mining: Interpretive Approach to Bankruptcy. *Journal of Management Information Systems*, 16(1), 63-85.
- Taffler, R. J. (1982). Forecasting Company Failure in the UK using Discriminant Analysis and Financial Ratio Data. *Journal of the Royal Statistical Association*, 145(3), 342-358.
- Tam, K. & Kiang, M. (1992). Managerial Applications of Neural Networks: The Case of Bank Failure Predictions. *Management Science*, 38(7), 926-947.
- Tennyson, B. M., Ingram, R. W. & Dugan, M. T. (1990). Assessing the Information Content of Narrative Disclosures in Explaining Bankruptcy. *Journal of Business, Finance & Accounting*, 17(3), 391-410.

- Ward, T. J. (1994). Cash Flow Information and the Prediction of Financially Distressed Mining, Oil and Gas Firms: A Comparative Study. *Journal of Applied Business Research*, 10(3),78-86.
- Weiss, S. M. & Kulikowsky, C. A. (1991). *Computer Systems that Learn*. CA: Morgan Kaufmann.
- Wilcox, J. W. (1971). A Simple Theory of Financial Ratios as Predictors of Failure. *Journal of Accounting Research*, 9(2), 389-395.
- Wilson, R. L. & Sharda, R. (1994). Bankruptcy Prediction Using Neural Networks. *Decision Support Systems*, 11, 545-557.
- Zavgren, C. V. (1985). Assessing the Vulnerability to Failure of American Industrial Firms: A Logistic Analysis. *Journal of Business Finance & Accounting*, 12(1), 19-45.
- Zhang, G., HU, M. Y., Patuwo, B. E. & Indro, D. C. (1999). Artificial Neural Network in Bankruptcy Prediction: General Framework and Cross-Validation Analysis. *European Journal of Operational Research*, 116, 16-32.
- Zmijewski, M. E. (1984). Methodological Issues Related to the Estimation of Financial Distress Prediction Models, *Journal of Accounting Research*, 22, Supplement, 59-82.