

A estatística multivariada na análise econômico-financeira de empresas

Jair Mendes Marques*
José Donizetti de Lima**

Resumo

O presente estudo teve como objetivo analisar o desempenho de empresas para fins de concessão de crédito, através das variáveis contábeis. A metodologia do estudo propôs uma análise estatística dos dados (teste T^2 de Hotelling e descartes de *outliers* e variáveis), seguida dos métodos discriminantes: Função Discriminante Linear de Fisher (FDLF) e Modelo de Regressão Logístico Múltiplo (MRLM). Na avaliação dos modelos foi utilizado o método de Lachenbruch. A implementação de funções no *software* MATLAB possibilitou a determinação dos resultados necessários. Considera-se como resultados importantes encontrados: os descartes terem sido de fundamental importância e, principalmente, a eficiência dos modelos para o objetivo proposto, pois resultados promissores foram encontrados: MRLM (93,18%) e FDLF (91,67%).

Palavras-chave: reconhecimento de padrões; análise de crédito; análise multivariada.

Abstract

The aim of the present paper is to analyze the performance of companies of credit concession, through accounting variables. The methodology of the study proposes, firstly, a statistical analysis of the data (T^2 test of Hotelling and discarded outliers and variables) and then discriminatory methods: Fisher Discriminating Linear Function (FDLF) and Lachenbruch Multiple Logistic Regression Model. An implementation of functions in MATLAB software provided the establishment of the needed results. It is considered as important results found: the discards having been of fundamental importance and, most of all, the efficiency of models for the pre-set aim. As promising results it was found: MRLM (93.18%) and FDLF (91.67%).

Key words: pattern precognition; credit analysis; multivariate analysis.

* Doutor em Ciências Geodésicas pela Universidade Federal do Paraná (UFPR). Professor da Universidade Federal do Paraná, Professor da FAE Business School e de pós-graduação da Universidade Tuiuti do Paraná (UTP)
E-mail: jair.marques@utp.br

** Mestre em Métodos Numéricos em Engenharia pela Universidade Federal do Paraná (UFPR). Professor do CEFET-Pato Branco, PR.
E-mail: donizetti@pb.cefetpr.br

Introdução

No atual contexto da economia brasileira figuram os juros altos (uma das maiores taxas de juros do Mundo Ocidental), o aumento do desemprego e uma pesada carga tributária. Na vizinha Argentina, aumento drástico da situação de risco. Na economia americana, principalmente no segundo semestre de 2001, ocorre um declínio forçado. Todos esses fatores concorrem para um crescimento mais modesto da economia brasileira e para a redução da oferta de crédito. A falta de crédito é um dos principais obstáculos para a geração de novos empregos. Por outro lado, a existência de crédito a uma taxa de juros aceitável proporcionaria mais empregos e melhores condições de crescimento econômico ao país. Dessa forma, percebe-se a grande responsabilidade social em torno da questão.

A inadimplência é o principal fator que aflige qualquer instituição financeira. Afinal, a aprovação dos créditos e a definição das taxas a serem cobradas são decorrentes dos riscos que envolvem a carteira de operações (portfólios).

Para Steiner et al. (1999), qualquer erro na decisão de concessão de crédito pode significar que em uma única operação haja a perda do ganho obtido em dezenas de outras bem-sucedidas, visto que o não recebimento representa a perda do montante emprestado. Assim, é importante prever a inadimplência, pois os prejuízos com operações malsucedidas provavelmente serão cobertos com a cobrança de uma sobretaxa a novos créditos, ou seja, encarecem-se as operações futuras.

Segundo Matarazzo (1998), é comum dois analistas de balanços chegarem a conclusões diferentes a respeito de balanços de uma mesma empresa. Logo, um processo decisório, sem se basear no *feeling* do tomador de decisões, torna-se de fundamental importância.

1 Metodologia

O objetivo deste estudo é, através de índices econômico-financeiros coletados dos demonstrativos contábeis de empresas – Balanço Patrimonial (BP) e Demonstração do Resultado do Exercício (DRE) –, classificá-las como adimplentes ou inadimplentes, visando diminuir o risco de inadimplência. Para alcançar tais objetivos, são propostas técnicas estatísticas multivariadas, a citar: Função Discriminante Linear de Fisher (FDLF), Modelo de Regressão Logístico Múltiplo (MRLM) e, ainda, um método de avaliação desses procedimentos (abordagem de Lachenbruch – metodologia *jackknife*).

Consideram-se também como objetivos: a validade do tratamento estatístico dos dados, preliminar à aplicação dos métodos discriminatórios propostos; e a construção de um programa computacional, no *software* MATLAB, para determinar os resultados dos testes estatísticos e estimar os parâmetros dos modelos discriminatórios propostos, além da avaliação de precisão desses modelos construídos.

Não é finalidade deste trabalho prever o custo de inadimplência, ou mesmo o lucro gerado por uma empresa adimplente. Assumiu-se, como adimplência ou inadimplência, a capacidade ou incapacidade de a empresa pagar as obrigações financeiras quando elas vencem.

Parte-se do pressuposto da veracidade das informações contidas nos indicadores contábeis. A partir da seleção de alguns índices considerados relevantes pela literatura, utilizam-se escores das duas primeiras Componentes Principais padronizadas para o descarte de observações (*outlier*), caso existam. Salienta-se, ainda, que os índices selecionados serão submetidos à eventual necessidade de redução do número de variáveis (via Componentes

Principais), ou seja, consideram-se diversas variáveis e reduz-se, caso necessário, o conjunto de variáveis para um subconjunto que possua maior precisão, através dos autovalores e autovetores da matriz de correlação.

O teste de hipótese, T^2 de Hotelling, é aplicado com a finalidade de verificar se as duas populações representadas por suas amostras são provenientes de populações distintas, ou seja, se existe diferença nas suas várias características médias.

1.1 Caracterização da amostra

A amostra caracteriza-se por empresas saudáveis e empresas com problemas. Os dados de empresas, utilizados neste trabalho, foram selecionados dos arquivos do Banco Regional de Desenvolvimento do Extremo Sul (BRDE), sediado em Curitiba-PR, de forma aleatória, contendo

informações de empresas solventes e empresas insolventes. A amostra foi tomada de maneira sistemática, com intervalo padronizado por um funcionário do banco, resguardando-se os nomes das empresas, por exigência do próprio banco. Dadas as características das empresas analisadas, e sendo as mesmas potenciais tomadoras de recurso junto ao BRDE, há uma grande concentração de empresas consideradas saudáveis (de um total de 136 empresas, escolhidas aleatoriamente, há 118 empresas adimplentes e apenas 18 empresas inadimplentes).

1.2 Indicadores econômico-financeiros

O quadro a seguir apresenta os indicadores (financeiros e econômicos) e as 8 variáveis utilizadas inicialmente para o tratamento estatístico dos dados.

QUADRO 1 - INDICADORES ECONÔMICO-FINANCEIROS

Índices de Estrutura de Capitais (Retirados do Balanço Patrimonial (BP) - Ind. financeiros)

Participação de Capital de Terceiros ($PCT = PC + ELP / PL$)

Imobilização do Patrimônio Líquido ($IPL = AP / PL$)

Índices de Liquidez (Retirados do Balanço Patrimonial - Ind. financeiros)

Liquidez Seca ($LS = AC - Est - Des / PC$)

Liquidez Corrente ($LC = AC / PC$)

Liquidez Geral ($LG = AC + RLP / PC + ELP$)

Margem de Garantia ($MG = AT / PC + ELP$)

Índices de Rentabilidade (Retirados da Demonstração do Resultado do Exercício (DRE) - Ind. Econômicos)

Retorno sobre Vendas ($RsV = LL / VL$)

Retorno sobre Patrimônio Líquido ($RPL = LL / PL - LL$)

Sendo:

AC = Ativo Circulante; PC = Passivo Circulante; AP = Ativo Permanente; AT = Ativo Total

ELP = Exigível a Longo Prazo; RLP = Realizável a Longo Prazo; VL = Vendas Líquidas

PL = Patrimônio Líquido; LL = Lucro Líquido; Des = Despesas do Exercício Seguinte;

Est = Estoques; Ind = Indicadores

Tomando como ponto de partida os dados das 136 empresas (fornecidos pelo BRDE) contendo os valores para as variáveis apresentadas anteriormente e aplicando o descarte de *outlier* (via componentes principais), verificou-se que 4 empresas possuíam valores discrepantes (ponto de vista contábil) em alguns índices, sendo as mesmas descartadas do banco de dados.

De posse das 132 empresas restantes, aplicou-se o descarte de variáveis (também utilizando-se de Componentes Principais) para verificar a necessidade de redução do número de variáveis, tendo como resultado a possibilidade de se trabalhar apenas com as seguintes variáveis: MG, IPL, LS e RPL.

Logo, a matriz inicial, de ordem 136x8, foi reduzida a uma matriz cujas dimensões passaram a ser 132x4, reduzindo significativamente o banco de dados. A aplicação da Função Discriminante Linear de Fisher e do Modelo de Regressão Logístico Múltiplo se deu a esse banco de dados.

Portanto, os métodos de análise discriminante multivariada foram aplicados a duas populações munidas de uma partição definida *a priori*, descritas por 4 variáveis explicativas (ou preditoras), e o objetivo principal foi construir uma regra de decisão utilizando uma amostra constituída de 132 empresas descritas pelas 4 variáveis, sendo conhecido o grupo *a priori* a que pertenciam.

1.3 Função Discriminante Linear de Fisher (FDLF)

Segundo Johnson e Wichern (1998), a FDLF, basicamente, consiste em separar duas classes de

objetos ou fixar um novo objeto em uma das duas classes. Ao definir a FDLF, é comum denominar as classes (populações) de π_1 e π_2 , e os objetos, separados ou classificados com base nas medidas de p variáveis aleatórias são associados com vetores do tipo $X' = [X_1, X_2, \dots, X_p]$.

O objetivo de Fisher, ao criar essa regra de reconhecimento de padrões e classificação, foi transformar as observações multivariadas X 's nas observações univariadas Y 's, tal que os Y 's das populações π_1 e π_2 fossem separados em relação às médias das duas populações tanto quanto possível. Fisher teve a idéia de tomar combinações lineares de X para criar os Y 's, dado que essas combinações são funções de X e, por outro lado, são facilmente calculáveis (ZUGE e CHAVES NETO, 1999).

Seja μ_{1Y} a média dos Y 's obtidos dos X 's pertencentes a π_1 e μ_{2Y} a média dos Y 's obtidos dos X 's pertencentes a π_2 e, considerando a matriz de covariância, Σ , como sendo a mesma para ambas populações, então Fisher selecionou a combinação linear que maximiza a razão entre o "quadrado da distância entre as médias" e a "variância de Y ", ou seja:

$$\frac{(\mu_{1Y} - \mu_{2Y})^2}{\sigma_Y^2} = \frac{[C'(\mu_1 - \mu_2)]^2}{C'\Sigma C}$$

Essa razão é maximizada por: $C = \Sigma^{-1}(\mu_1 - \mu_2)$, e, assim, tem-se: $Y = C'X = (\mu_1 - \mu_2)' \Sigma^{-1} X$, que é conhecida como FDLF populacional.

Como, na realidade, os parâmetros μ_1, μ_2 e Σ não são conhecidos, devem-se usar seus estimadores, ou seja, \bar{x}_1 estima μ_1 , \bar{x}_2 estima μ_2 e a matriz de covariância conjunta (estimada) é dada por:

$$S_p = \frac{(n_1 - 1)S_1 + (n_2 - 1)S_2}{n_1 + n_2 - 2}$$

Dessa forma, a FDLF amostral fica determinada por:

$$Y = (\bar{X}_1 - \bar{X}_2)' S_p^{-1} X$$

A estimativa do ponto médio amostral é dada por:

$$\hat{m} = \frac{1}{2} [(\bar{X}_1 - \bar{X}_2)' S_p^{-1} (\bar{X}_1 + \bar{X}_2)]$$

Obtém-se, desta forma, a seguinte regra de classificação:

- Alocar X_0 em π_1 se $\hat{y}_0 = (\bar{X}_1 - \bar{X}_2)' S_p^{-1} X_0 \geq \hat{m}$
ou
- Alocar X_0 em π_2 ,
se $\hat{y}_0 = (\bar{X}_1 - \bar{X}_2)' S_p^{-1} X_0 < \hat{m}$

1.4 Modelo de regressão logístico múltiplo (MRLM)

O Modelo de Regressão Logístico Múltiplo é uma técnica estatística comumente usada para a análise de dados com resposta binária (dicotômica) e consiste em relacionar, através de um modelo, a variável resposta com os fatores que influenciam a ocorrência de um determinado evento. Por exemplo, o quanto os índices de estrutura de capitais, liquidez e rentabilidade explicam o risco de inadimplência.

Como no presente estudo a variável resposta é dicotômica, o modelo de regressão linear não deve ser utilizado, pois poder-se-á obter valores de resposta estimada fora do intervalo [0,1], não sendo neste caso compatível com a natureza do fenômeno estocástico. Além disso, facilmente se mostra que a condição de variância constante para os resíduos não se verifica.

Sejam uma variável aleatória Y (dicotômica, ou seja, assumindo apenas os valores 0 ou 1) e $X' = [X_1, X_2, \dots, X_p]$ um vetor de dimensão p, composto de variáveis aleatórias independentes, e ainda tomando-se n observações independentes,

pode-se escrever o Modelo de Regressão Logística Múltiplo na forma:

$$P(X) = \frac{e^{\beta'X}}{1 + e^{\beta'X}}, \text{ para}$$

$$\beta' = [\beta_0, \beta_1, \dots, \beta_p] \text{ e } X = [1, X_1, \dots, X_p]$$

Este modelo é o mais apropriado no caso de a variável dependente ser dicotômica, pois a Regressão Logística estima diretamente a probabilidade de ocorrência de um evento. Salienta-se também que a estimação dos parâmetros deve ser feita pelo método de máxima verossimilhança, sendo o mais recomendado quando se dispõem de observações individuais da ocorrência ou não de determinado evento. Esse método fornece estimativas para os parâmetros que maximizam a probabilidade de obter o conjunto observado de dados. Assim, tomando uma amostra aleatória composta de n pares de observações (X_i, Y_i) com $i = 1, 2, \dots, n$, onde os Y's representam os valores observados de uma variável dicotômica e os X's representam os valores observados de p variáveis independentes.

Uma forma conveniente para expressar a contribuição da função de verossimilhança para os pares (X_i, Y_i) é através da fórmula:

$$F(X_i) = P(X_i)^{Y_i} [1 - P(X_i)]^{1 - Y_i}$$

Desde que assumido que as observações são independentes, a função de verossimilhança é obtida como o produto dos termos dados na equação anterior:

$$l(\beta) = \prod_{i=1}^n F(X_i) = \prod_{i=1}^n [P(X_i)]^{Y_i} [1 - P(X_i)]^{1 - Y_i}$$

Assim, a função de log-verossimilhança fica determinada por:

$$L(\beta) = \sum_{i=1}^n [Y_i \beta' X_i - \ln(1 + e^{\beta' X_i})]$$

Desta forma, estimar-se-ão $(p+1)$ equações de verossimilhança, as quais são obtidas por derivadas da função de log-verossimilhança com respeito a $(p+1)$ coeficientes. As equações de verossimilhança resultantes podem ser representadas como:

$$\frac{\partial L(\beta)}{\partial \beta_0} = \sum_{i=1}^n [Y_i - P(X_i)] = 0 \quad \text{e} \quad \frac{\partial L(\beta)}{\partial \beta_j} = \sum_{i=1}^n X_{ij} [Y_i - P(X_i)] = 0$$

para $j = 1, 2, \dots, p$.

o que reflete no fato de a soma dos valores observados de Y ser igual à soma dos valores esperados (preditos), mediante a aplicação do modelo obtido. Esta propriedade é importante, pois ajuda a avaliar o ajuste do modelo.

A estimação dos parâmetros para o MRLM foi feita com base nos estimadores de Máxima Verossimilhança, e o seu cálculo foi obtido através do método de Levenberg-Marquardt. Em termos da aferição da qualidade global do modelo logístico, foi utilizado o critério baseado nos resultados de classificação obtidos com esse modelo.

O método de Levenberg-Marquardt foi utilizado para determinar os estimadores de máxima verossimilhança do modelo de regressão logístico múltiplo. Esse método trabalha com uma variação suave entre os extremos dos métodos de Newton e do Gradiente, sendo que se utiliza este último quando se está longe do mínimo, visto que o método de Newton pode não convergir nesta situação. Por outro lado, quando se está distante da solução usa-se o método do Gradiente. Esse método combina os métodos do Gradiente e de Newton através da alteração dos elementos da diagonal principal da matriz hessiana.

No presente estudo, o critério de parada foi estabelecido a partir de duas considerações: a primeira se relaciona ao fato de que, analisando as derivadas parciais da função de log-verossimilhança, tem-se que a soma dos valores

observados deve ser igual à soma dos valores preditos, e a segunda está baseada no fato de uma nova solução não trazer alteração no valor da função objetivo (log-verossimilhança). Assim, o processo iterativo é suspenso apenas quando as duas condições descritas anteriormente forem satisfeitas.

1.5 Avaliação da função de classificação: A abordagem de Lachenbruch

O método de Lachenbruch, segundo Johnson e Wichern (1998), é uma abordagem estatística empregada para avaliar o desempenho da regra de reconhecimento de padrões e estimar a probabilidade de classificação correta e incorreta em cada grupo, ou seja, uma forma de avaliar a eficiência da regra de classificação. O algoritmo do referido procedimento é descrito a seguir:

- Passo 1: Inicie com as observações do grupo π_1 , omita uma observação desse grupo e construa uma função de classificação usando as (n_1-1) restantes do grupo π_1 acrescidas das n_2 observações do grupo π_2 .
- Passo 2: Classifique a observação retida, usando a função construída no passo 1.
- Passo 3: Repita os passos 1 e 2 até que todas as observações de π_1 sejam classificadas. Seja $n_{2/1}$ o número de observações reconhecidas erroneamente nesse grupo.
- Passo 4: Repita os passos de 1 a 3 para as n_2 observações do grupo π_2 . Seja $n_{1/2}$ o número de observações reconhecidas erroneamente nesse grupo.

Assim, as estimativas das probabilidades de classificação incorreta são dadas por:

- $\hat{P}(2/1) = \frac{n_{2/1}}{n_1}$ (classificar em π_2 , quando a observação pertence a π_1)
- $\hat{P}(1/2) = \frac{n_{1/2}}{n_2}$ (classificar em π_1 , quando a observação pertence a π_2)

Desta forma, a proporção esperada de erro é dada por:

$$\hat{E}(\text{AER}) = \frac{n_{1/2} + n_{2/1}}{n_1 + n_2}$$

2 Resultados

Na tabela 1, a seguir, são apresentados os principais resultados obtidos para a análise da Função Discriminante Linear de Fisher.

TABELA 1 - COEFICIENTES DA FDLF

VARIÁVEL	COEFICIENTE DA FDLF (C)
MG = AT / (PC + ELP)	0.0828
IPL = AP / PL	-0.0235
LS = (AC - Est - Des) / PC	0.3004
RPL = LL / PL	0.0522

Assim, a aplicação da metodologia FDLF, na amostra em estudo, resultou na seguinte função de classificação:

$$Y = 0.0828*MG - 0.0235*IPL + 0.3004*LS + 0.0522*RPL$$

Desta forma, ao multiplicar esse vetor C' de dimensão quatro (4 indicadores) pelos valores de uma nova observação, tem-se um escore. Se esse for maior que o ponto médio (\hat{m}), classificar-se-á na população das empresas adimplentes; caso contrário, deve ser classificado no grupo das empresas inadimplentes. O ponto médio a ser utilizado para fazer a decisão de classificação foi estimado por: $\hat{m} = -3.7946$.

A probabilidade de classificação correta para a FDLF é de 91,67%, avaliada pelo método de Lachenbruch. Veja demais detalhes na tabela 2.

TABELA 2 - RESULTADOS DE CLASSIFICAÇÃO PARA A FDL

POPULAÇÃO	Nº DE EMPRESAS	TAXA (%)
População 1		
Certo	109	94,78
Errado	6	5,22
População 2		
Certo	12	70,59
Errado	5	29,41

NOTA: Probabilidade de classificação correta = 91.67%

Salienta-se que o resultado encontrado para a FDLF é melhor do que o resultado que inclui as 132 empresas com suas 8 variáveis, ou seja, sem efetuar o descarte de variáveis. Assim, considera-se de grande utilidade o descarte de variáveis, desde que bem fundamentado, pois neste estudo o número de medidas (variáveis) foi reduzido em 50% e resultados promissores foram encontrados.

A tabela a seguir apresenta os coeficientes e os erros padrões estimados para o Modelo de Regressão Logístico Múltiplo, tendo por base os estimadores de máxima verossimilhança obtidos através do método de Levenberg-Marquardt.

TABELA 3 - COEFICIENTES DO MRLM

VARIÁVEL	COEFICIENTE DO MRLM	ERRO PADRÃO
Constante	0,0789	1,2686
MG	0,4717	0,5385
IPL	-0,0133	0,0047
LS	5,1297	1,8334
RPL	0,0465	0,0188

Assim a aplicação do MRLM, na amostra em estudo, resultou no seguinte modelo:

$$P(X) = \frac{e^{0,0789 + 0,4717 * MG - 0,0133 * IPL + 5,1297 * LS + 0,0465 * RPL}}{1 + e^{0,0789 + 0,4717 * MG - 0,0133 * IPL + 5,1297 * LS + 0,0465 * RPL}}$$

O valor obtido por P(X) representa a probabilidade de a empresa ser adimplente. O valor *cut off score*, o qual maximiza a probabilidade de acerto, foi igual a 0.5. A tabela a seguir apresenta os resultados de classificação para o MRLM, avaliado pela abordagem de Lachenbruch.

TABELA 4 - RESULTADOS DE CLASSIFICAÇÃO PARA O MRLM

POPULAÇÃO	N.º DE EMPRESAS	TAXA (%)
POPULAÇÃO 1		
Certo	110	95,65
Errado	5	4,35
POPULAÇÃO 2		
Certo	13	76,47
Errado	4	23,53

NOTA: Probabilidade de classificação correta 93,18= %

De acordo com as tabelas 2 e 4, observa-se uma porcentagem de classificação correta superior, através do Modelo de Regressão Logístico Múltiplo, em todos os quesitos avaliados. Salienta-se que a taxa de erro tipo II teve uma redução significativa, pois esse tipo de erro passou de 29,41% para 23,52%, o que é relevante, pois está se concedendo empréstimo a uma empresa que não vai pagar, ocasionando a perda dos juros e do montante emprestado.

Um resultado comparativo entre os métodos propostos (FDLF e MRLM), obtido através da abordagem de Lachenbruch, é apresentado no quadro a seguir.

A notação POP(i|j) representa o número de elementos da população j que foi classificado na população i, estando os mesmos corretamente classificados quando i = j, e incorretamente, caso contrário.

QUADRO 2 - COMPARAÇÃO ENTRE OS MODELOS DESENVOLVIDOS

POPULAÇÃO / MÉTODO	FDLF		MRLM	
	Abs.	%	Abs.	%
Pop. (1 1)	109	94,78	110	95,65
Pop. (2 1)	6	5,22	5	4,35
Pop. (2 2)	12	70,59	13	76,47
Pop. (1 2)	5	29,41	4	23,53
TOTAL	132	100,00	132	100,00
Acerto	121/132 =	91,67	123/132 =	93,18

Conclusão

As técnicas abordadas neste trabalho, se empregadas corretamente, constituem-se em eficientes ferramentas auxiliares dos gestores de crédito, ou seja, os modelos desenvolvidos poderão auxiliar os analistas de créditos bancários no processo de tomada de decisões e previsão do comportamento de futuras empresas.

Salientam-se, como primeira conclusão importante, os resultados positivos encontrados com a estimação dos parâmetros após a análise preliminar dos dados (T^2 de Hotelling e os descartes de *outlier* e variáveis). Portanto, é relevante uma análise estatística rigorosa antes da aplicação dos métodos de discriminação.

O MRLM foi o que apresentou melhor desempenho, quando analisado em relação ao percentual de classificação correta em cada um dos itens avaliados (erros tipo I e tipo II, e acerto global). Por outro lado, a FDLF apresentou um percentual de classificação correta inferior ao MRLM, mas esta técnica é bastante eficiente, pois sua porcentagem de classificação correta foi superior a 91%.

Para a presente amostra, conclui-se que a FDLF e o MRLM são duas técnicas eficientes na discriminação das empresas adimplentes e inadimplentes, evidenciando certa melhora para

a segunda técnica em relação à primeira. Apesar desta evidência, não se pode contestar a eficiência das referidas técnicas para o objetivo proposto.

A diferença verificada em relação à eficiência dos dois procedimentos desenvolvidos não constitui empecilho à sua utilização. Ao contrário, possibilita ao tomador de decisões a escolha da técnica que apresente uma maior probabilidade de classificação correta, o que fortalece o fator

“segurança”, tendo em vista o montante de recursos envolvidos nas operações de créditos às empresas.

O desenvolvimento do programa computacional foi importante, pois possibilitou a análise preliminar dos dados, a estimação dos parâmetros para ambos os modelos construídos (FDLF e MRLM), a avaliação da eficiência dos mesmos e, ainda, a classificação de uma nova empresa solicitadora de crédito.

Referências

- ALTMAN, E. L. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance*, Pittsburgh, PA, v. 23, n. 4, p. 589-609, sept. 1968.
- JOHNSON, R. A.; WICHERN, D. W. *Applied multivariate statistical analysis*. 4. ed. Nova Jersey: Prentice-Hall, inc., 1998.
- MARION, J. C. *Contabilidade empresarial*. 8. ed. São Paulo: Atlas, 1998.
- MATARAZZO, D. C. *Análise financeira de balanços: abordagem básica e gerencial*. 5. ed., São Paulo: Atlas, 1998.
- STEINER, M. T. A.; CARNIERI, C.; STEINER NETO, P. J.; KOPITKE, B. Sistemas especialistas probabilístico e redes neurais na análise do crédito bancário. *Revista de Administração*, São Paulo, v. 34, n. 3, p. 56-67, jul./set. 1999.
- ZÜGE, M.; CHAVES NETO, A. Utilização dos métodos estatísticos multivariados na avaliação do desempenho empresarial. *Revista Paranaense de Desenvolvimento, Economia e Sociedade*, Curitiba, n. 97, p. 101-112, set./dez. 1999.