

# PROCEDIMENTO DE RETENÇÃO DE LACHENBRUCH PARA AVALIAR O MELHOR MÉTODO DE CLASSIFICAÇÃO DE FORNECEDORES DE PRODUTOS

**Sonia Isoldi Marty Gama Müller**

UFPR – Universidade Federal do Paraná, departamento de Estatística  
Centro Politécnico, Edifício de Administração, 3º andar, Curitiba-PR  
soniaisoldi@ufpr.br

**Paulo Henrique Siqueira**

UFPR – Universidade Federal do Paraná, departamento de Expressão Gráfica  
Centro Politécnico, Edifício de Administração, 4º andar, Curitiba-PR  
paulohs@ufpr.br

## RESUMO

Avaliação de fornecedores é uma atividade que promove para a empresa uma melhoria significativa no processo de produção, principalmente na qualidade dos insumos, e na redução dos prazos de entrega. O objetivo deste trabalho é propor um método eficaz no reconhecimento e classificação das novas empresas que integrarão a lista de fornecedores avaliados pela empresa. Através do procedimento de retenção de Lachenbruch comparou-se um método de classificação estatístico com outro de inteligência artificial utilizando dados reais de uma empresa de grande porte. Os métodos apresentaram desempenhos similares quando foi aplicado um teste de comparação de proporções das classificações corretas utilizando um nível de significância de 5%, onde os gestores da empresa podem escolher o método de classificação.

**PALAVRAS CHAVE.** Reconhecimento de Padrão e Classificação. Redes Neurais Artificiais. Análise Multivariada. Aplicações à Indústria

## ABSTRACT

*Suppliers evaluation is an activity that promotes for the company a significant improvement in the production process, mainly of one better quality of the inputs, and the reduction in delivery periods. The objective of this paper is to propose an efficient method in the recognition and classification of new companies who will go to integrate the list of suppliers evaluated for the company. Through the Lachenbruch's holdout procedure a statistical method of classification with another one of artificial intelligence using real data of a large company was compared. The methods presented similar performances when it was applied to test comparison of proportions of correct classifications using a significance level of 5%, where the managers of the company can be made the choice of the classification model.*

**KEYWORDS.** *Pattern Recognition and Classification. Artificial Neural Networks. Multivariate Analysis. Applications to the Industry*

## 1. Introdução

Avaliação de Fornecedores é uma atividade que recentemente vem sendo feita nas empresas. Nos últimos anos, o mercado exige que as empresas se preocupem com avaliação de seus fornecedores para garantir melhoria da qualidade nos produtos, nos custos, prazos de entrega e conseqüentemente na sua competitividade. Com a recente tendência do “just-in-time” (JIT), filosofia de fabricação em tempo real, recentemente existe uma ênfase em estabelecer uma relação de benefícios mútuos entre a empresa e os melhores fornecedores.

A avaliação consiste da obtenção de um escore para cada fornecedor com base num conjunto de informações que permite identificar o comportamento deste nas questões referentes a compras (preços, prazos de pagamentos, etc.), logística (prazos de entrega, estratégias operacionais, estoques, etc.), qualidade (acordos de qualidade, adequação na certificação, qualidade de recebimento, etc.) e tecnologia (desempenho tecnológico, requisitos técnicos, adequação em tecnologias futuras, etc.). Comumente é feito um ranqueamento dos fornecedores com base em pesos pré-estabelecidos pelos gestores para tomadas de decisões ou possível premiação dos melhores.

O objetivo principal deste trabalho é proporcionar às empresas uma metodologia que possibilite que um fornecedor recentemente incluído no quadro seja avaliado de modo que se possa prever o seu desempenho. A idéia é alocar um novo indivíduo em um dos três grupos: bom (parceiro com qualidade assegurada), regular (melhoria solicitada) ou ruim (inaceitável). Assim, utilizando técnicas de reconhecimento de padrões é possível fazer uma pré-avaliação deste fornecedor de acordo com as expectativas da empresa.

Dois técnicas de reconhecimento de padrões são propostas neste trabalho: uma Estatística, o Discriminante Linear de Fisher, e outra da área de Inteligência Artificial, a Rede Neural Artificial do tipo Perceptron com Múltiplas Camadas. A escolha destas técnicas é justificada pelos bons desempenhos apresentados por elas tanto no problema específico deste trabalho, quanto em outros problemas mostrados na literatura.

Para a comparação entre os métodos utilizou-se o procedimento de Retenção de Lachenbruch descrito por JOHNSON & WICHERN (1992) que mostra o denominado verdadeiro desempenho de classificação.

Os dados mostrados neste trabalho foram coletados numa empresa de grande porte que não permitiu sua identificação para preservar as identidades de seus fornecedores.

Este trabalho está dividido em 4 seções, incluindo esta introdução. Na seção 2, as técnicas utilizadas neste trabalho são apresentadas. A metodologia de aplicação destas técnicas no problema de classificação de fornecedores é mostrada na seção 3. Na seção 4 são apresentados os resultados e a conclusão do trabalho.

## **2. Metodologia**

As duas técnicas apresentadas neste trabalho são bastante conhecidas na literatura para resolver problemas de classificação. Nesta seção são apresentadas tais técnicas, que são aplicadas com o procedimento de retenção de Lachenbruch para comparação dos resultados.

### **2.1. Método Discriminante Linear de Fisher**

A alocação de um novo indivíduo (empresa), conhecido como Classificação baseia-se na atribuição de classes para estes indivíduos (empresas) através do processo denominado de Reconhecimento de Padrão e Classificação.

O Método Discriminante Linear de Fisher para várias populações, segundo JOHNSON & WICHERN (1992), é uma extensão do mesmo método para duas populações. A suposta gaussianidade não é necessária neste método, no entanto é preciso considerar que as matrizes de covariâncias dos grupos analisados sejam iguais.

Sejam vetores de observações  $X$  com  $p$  variáveis, identificados entre os  $g$  possíveis grupos. O objetivo do método é construir  $s$  combinações lineares das  $p$  variáveis que melhor discriminam entre  $g$  grupos designados. Estas observações multivariadas ( $X$ ) transformam-se em outras univariadas ( $Y$ ) que são combinações lineares de  $X$ .

Supondo que a série treinada é uma amostra aleatória de tamanho  $n_i$  da população  $\Pi_i$ , onde

$i = 1, 2, \dots, g$ , tem-se o vetor de média amostral é dado por  $\bar{x}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_{ij}$  e o vetor de média global

estimado é definido abaixo, oriundo do vetor médio obtido de todas as observações de uma série treinada dado por:

$$\bar{x} = \frac{\sum_{i=1}^g \sum_{j=1}^{n_i} x_{ij}}{\sum_{i=1}^g n_i}$$

A matriz estimada de  $B_0$  que corresponde à matriz soma dos produtos cruzados "entre" os grupos populacionais pode ser obtida através de:

$$\hat{B}_0 = \sum_{i=1}^g (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})'$$

A estimativa da matriz da soma dos produtos cruzados "dentro" dos grupos amostrais ( $W$ ) é apresentada abaixo, onde  $S_i$  é a matriz de covariância de cada grupo:

$$W = \sum_{i=1}^g (n_i - 1)S_i = \sum_{i=1}^g \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)(x_{ij} - \bar{x}_i)'$$

Então a estimativa de  $\Sigma$  chamada de matriz de covariância conjunta é dada por:

$$\hat{\Sigma} = S_c = \frac{W}{(n_1 + n_2 + \dots + n_g - g)}$$

Tendo em vista que o mesmo  $\hat{\ell}$  que maximiza  $\frac{\hat{\ell}' \hat{B}_0 \hat{\ell}}{\hat{\ell}' S_c \hat{\ell}}$  também maximiza  $\frac{\hat{\ell}' \hat{B}_0 \hat{\ell}}{\hat{\ell}' W \hat{\ell}}$ , então se pode apresentar a otimização de  $\hat{\ell}$  na forma de autovetores,  $\hat{e}_i$  de  $W^{-1} \hat{B}_0$ , pois se  $W^{-1} \hat{B}_0 \hat{e} = \hat{\lambda} \hat{e}$  então:

$$S_c^{-1} \hat{B}_0 \hat{e} = \hat{\lambda} \cdot (n_1 + n_2 + \dots + n_g - g) \cdot \hat{e}$$

Portanto o Discriminante Amostral de Fisher para Várias Populações pode ser definido como segue: sejam  $\hat{\lambda}_{-1}, \hat{\lambda}_{-2}, \dots, \hat{\lambda}_{-s} > 0$  os autovalores não nulos de  $W^{-1} \hat{B}_0$  e  $\hat{e}_1, \hat{e}_2, \dots, \hat{e}_s$  os correspondentes autovetores. Então, o vetor de coeficientes  $\hat{\ell}$  que maximiza a razão  $\frac{\hat{\ell}' \hat{B}_0 \hat{\ell}}{\hat{\ell}' W \hat{\ell}}$  é dado por  $\hat{\ell}_1 = \hat{e}_1$  e a combinação linear  $\hat{\ell}_1' x = \hat{e}_1' x$  é chamada de 1º Discriminante Amostral;  $\hat{\ell}_2 = \hat{e}_2$  produz o 2º Discriminante Amostral  $\hat{\ell}_2' x = \hat{e}_2' x$ , generalizando tem-se que  $\hat{\ell}_k' x = \hat{e}_k' x$  é o k-ésimo Discriminante Amostral para  $k \leq s$ .

Os resultados fornecem subsídios para classificar novos valores a partir do cálculo das distâncias euclidianas entre o valor da função discriminante no ponto selecionado e os valores das funções discriminantes dos valores médios dos grupos (populações), então a população escolhida é a que tenha menor distância. Para tanto, segue a regra:

Alocar  $x$  na população  $\Pi_k$  se:

$$\sum_{j=1}^r (\hat{y}_j - \bar{y}_{kj})^2 = \sum_{j=1}^r [\hat{\ell}'_j (x - \bar{x}_k)]^2 \leq \sum_{j=1}^r [\hat{\ell}'_j (x - \bar{x}_i)]^2 \quad \text{para todo } i \neq k$$

onde:

$$\hat{y}_j = \hat{\ell}'_j x \quad \text{e} \quad \bar{y}_{kj} = \hat{\ell}'_j \bar{x}_k \quad \text{com } r \leq s$$

## 2.2. Redes Neurais Artificiais

Uma Rede Neural Artificial (RNA) é definida como um sistema de processamento de informações com características de aprendizado semelhantes às das Redes Neurais Biológicas. Geralmente, os modelos de RNA possuem inspiração biológica, mas são algoritmos computacionais que representam o aprendizado humano de maneira bastante simples, através dos elementos de processamento chamados de neurônios (FAUSETT, 1994).

Existem diversos tipos de RNA, sendo que a Rede Perceptron de Múltiplas Camadas (MLP: Multi-Layer Perceptron) é uma das mais utilizadas para fazer reconhecimento de padrões (TINÓS, 1999; HAYKIN, 1999). O aprendizado desta rede pode ser feito de diversas maneiras, e a mais utilizada é a retropropagação do erro (backpropagation). A figura 1 mostra um exemplo de uma rede com a camada de entrada, uma camada escondida, e a camada de saída. Os valores das variáveis dos vetores  $z$  e  $y$  são calculados da seguinte forma:

$$z^* = v^T x + \theta, \text{ e } z = f(z^*);$$

$$y^* = w^T z + \theta_b, \text{ e } y = f(y^*),$$

onde a função de ativação  $f$  pode ser a tangente hiperbólica, sigmoideal ou linear:

$$f(x_k) = \tanh(\beta x_k) = \frac{e^{\beta x_k} - e^{-\beta x_k}}{e^{\beta x_k} + e^{-\beta x_k}}, \quad f(x_k) = \frac{1}{1 + e^{-\beta x_k}}, \quad \text{ou } f(x_k) = \beta x_k.$$




Figura 1: exemplo de uma RNA do tipo MLP com uma camada escondida

O aprendizado da RNA ocorre da seguinte maneira: dado o conjunto de entradas representado pelo vetor  $x$ , a rede calcula os valores das camadas escondidas até chegar na saída da rede, onde o vetor é representado como  $y$  (Figura 1). Os valores das variáveis de saída são então comparados com seus valores desejados  $d$ , e um vetor  $e$  com os erros da saída é calculado. Os valores das variáveis de cada camada são ajustados com a retropropagação do erro utilizando-se, geralmente, a regra do gradiente (FAUSETT, 1994). No exemplo mostrado na Figura 1, os valores dos ajustes são calculados da seguinte forma:

$$\text{erro do vetor } y: \delta = (d - y)f'(y^*); \Delta w = \delta \alpha z; \Delta \theta_b = \delta \alpha$$

$$\text{erro do vetor } z: \delta^* = \delta w; \delta = \delta^* f'(z^*); \Delta v = \delta \alpha x, \Delta \theta_a = \delta \alpha.$$

O aprendizado desta RNA é denominado supervisionado, pois os valores da saída são comparados com valores desejados. Existem redes que não possuem a saída conhecida, e são denominadas redes não-supervisionadas (HAYKIN, 1999).

### 2.3. Procedimento de Retenção de Lachenbruch

A comparação de metodologias de reconhecimento de padrões é comumente feita a partir da Taxa Aparente de Erro, mas segundo CHAVES NETO (2003) não é a mais indicada para se avaliar o desempenho do modelo, pois utiliza os mesmos dados usados no ajuste para fazer a avaliação. Um modo mais seguro de se medir a eficiência de qualquer método de reconhecimento e classificação é o Procedimento de Retenção de Lachenbruch que utiliza todas as informações um modo mais criterioso.

O Procedimento de Retenção de Lachenbruch de acordo com JOHNSON & WICHERN (1992) retém uma observação e utiliza todas as restantes na obtenção das equações do método proposto. Classifica-se essa observação num dos grupos e anota-se este resultado. Repete-se este procedimento até que todas as observações forem retidas e a seguir colocam-se os resultados na tabela de classificação.

Para entender melhor o procedimento apresenta-se a seguir o algoritmo descrito em MARQUES & LIMA (2002) para dois grupos de classificação e estendida aqui para vários grupos.

Passo 1: Inicie com as observações (amostras) do grupo 1, omita uma observação desse grupo e construa as funções de classificação usando as  $(n-1)$  restantes do grupo 1 acrescidas das  $n_p$  observações dos  $p$  grupos que compõem a análise;

Passo 2: Classifique a observação retida, usando as funções construídas no passo 1;

Passo 3: Repita os passos 1 e 2 até que todas as observações de todos os grupos sejam classificadas e construa a tabela de classificação.

### 3. Aplicações das metodologias propostas

Os dados dos fornecedores apresentados neste trabalho são disponibilizados por uma empresa de grande porte da região metropolitana de Curitiba. Esta empresa possui seleção e análise de fornecedores com procedimentos construídos ao longo de muitos anos de experiência. Estes procedimentos feitos em um departamento da empresa abrangem quatro características: compras, logística, qualidade e tecnologia.

A empresa classificou os dados dos 46 fornecedores de produtos segundo seus próprios critérios: 13 fornecedores bons, 23 regulares e 10 ruins. Esta empresa considera que um bom fornecedor é também um parceiro de trabalho, portanto possui vantagens em alguns itens, principalmente no que diz respeito ao controle de qualidade. O fornecedor regular recebe um tratamento diferenciado, pois precisa ser acompanhado no decorrer do ano para uma possível melhoria. No entanto, o fornecedor classificado como ruim é automaticamente desligado da empresa.

Para a implementação dos métodos escolhidos optou-se pelo programa *Statgraphics Centurion* para a técnica do Discriminante Linear de Fisher, e o *MATLAB 7.0* para as Redes Neurais Artificiais. Os parâmetros da Rede Neural Artificial MLP foram os mesmos para todos os testes, com 10 neurônios na camada escondida utilizando a função de ativação tangente hiperbólica, e na camada de saída a função de ativação linear.

O Procedimento de Retenção de Lachenbruch foi utilizado nos dois casos e os resultados obtidos são apresentados na seção a seguir.

### 4. Resultados e Discussão

Os resultados encontrados pelos dois métodos testados estão apresentados na tabelas 1 e 2, sendo que a primeira se refere às classificações obtidas pelo Método de Fisher e a segunda por Redes Neurais Artificiais.

Na Tabela 1 observa-se que foram classificados corretamente 13 fornecedores bons, 17 regulares e 6 ruins totalizando 36 fornecedores classificados corretamente com o método de Fisher, o que representa um percentual de acerto de 78,26%.

**Tabela 1:** Tabela de Contingência na Classificação feita pelo Método Linear de Fisher.

Grupos de Referência	Grupos Previstos			Total
	Bom	Regular	Ruim	
Bom	<b>13</b>	0	0	13
Regular	3	<b>17</b>	3	23
Ruim	0	4	<b>6</b>	10
Total	16	21	9	<b>46</b>

Fonte: Resultado obtido pelos autores no programa *Statgraphics Centurion*.

Na Tabela 2 observa-se que foram classificados corretamente 13 fornecedores bons, 20 regulares e 8 ruins totalizando 41 fornecedores que foram classificados corretamente pela Rede Neural MLP o que representa um percentual de acerto de 89,13%.

**Tabela 2:** Tabela de Contingência na Classificação feita pela Rede Neural MLP.

Grupos de Referência	Grupos Previstos			Total
	Bom	Regular	Ruim	
Bom	<b>13</b>	0	0	13
Regular	3	<b>20</b>	0	23
Ruim	0	2	<b>8</b>	10
Total	16	22	8	<b>46</b>

Fonte: Resultado obtido pelos autores no programa *MATLAB 7.0*

O teste de comparação de proporções foi aplicado aos resultados e concluiu-se que não há diferença entre as proporções observadas considerando o nível de significância de 5%, pois se obteve um p-valor de 0,15819. Portanto, apesar do método de Redes Neurais MLP apresentar um resultado melhor não se pode afirmar que seja significativamente diferente do obtido pelo método estatístico.

## 5. Conclusão

Dos procedimentos analisados neste trabalho, a Rede Neural MLP apresentou melhor desempenho que o Método Discriminante Linear de Fisher, pois o percentual de casos classificados corretamente do primeiro método resultou em 89,13% e do segundo 78,26%, porém não apresentando diferenças estatisticamente significativas.

A partir dos resultados encontrados pode-se propor aos gestores da empresa consultada um método eficiente de classificação de fornecedores que recentemente entraram no programa, isto é, a partir de uma primeira avaliação é possível identificar a provável situação da empresa com probabilidade de acerto de no mínimo 78,26%. Portanto, a empresa poderá escolher o método mais viável.

## Referências

- Chaves Neto, A.** *Introdução ao Reconhecimento de Padrões*. Curitiba: UFPR, 2003, 61 p. (notas de aula).
- Fausett, L.**, *Fundamentals of Neural Networks*. Prentice Hall, New Jersey, 1994.
- Fernandes, D.E.B.; Alves, M.F. e Júnior, P.P.C.** (2005), *Classificação de Padrões de Afundamentos de Tensão em Sistemas de Monitoramento da Qualidade da Energia Elétrica*, VI SBQEE, Belém, 690-696.
- Hair, J. F; Anderson, R. E.; Tatham, R. L. e Black, W. C.**, *Análise Multivariada de Dados*. Tradução: Adonay S. Sant'anna e Anselmo Chaves Neto, Bookman, 2005.
- Haykin, S.**, *Neural Networks – A Comprehensive Foundation*. Prentice Hall, New Jersey, 1999.
- Johnson R. A. e Wichern, D. W.**, *Applied Multivariate Statistical Analysis*. Prentice Hall International, New Jersey, 1992.
- Marques, J. M. e Lima, J. D.** *A Estatística Multivariada na Análise Econômica-Financeira de Empresas*. *Revista da FAE*, v. 5, n. 3, 51-59, Setembro 2002.
- Tinós, R.**, *Detecção e diagnóstico de falhas em robôs manipuladores via redes neurais artificiais* (Dissertação de Mestrado), São Carlos, USP, 1999.