

AILTON GUIMARÃES

**“PREVISÃO DE INSOLVÊNCIA: UM MODELO BASEADO EM ÍNDICES CONTÁBEIS
COM UTILIZAÇÃO DA ANÁLISE DISCRIMINANTE”**

Dissertação submetida ao Programa de Pós-Graduação Strictu Sensu em Economia de Empresas, área de concentração Finanças, da Universidade Católica de Brasília, como requisito para a obtenção do Título de Mestre.

Orientador: **Prof. Dr. Tito Belchior Silva
Moreira**

**Brasília
2006**

TERMO DE APROVAÇÃO

Dissertação defendida e aprovada como requisito parcial para obtenção do Título de Mestre em Economia de Empresas, área de concentração Finanças, em 25 de agosto de 2006, pela banca examinadora constituída por:

Prof. Dr. Tito Belchior Silva Moreira

Prof. Dr. Daniel Oliveira Cajueiro

Prof. Dr. Charles Lima de Almeida

Dedico o presente trabalho a minha família por me apoiar e incentivar em todos os momentos desta caminhada.

Agradeço imensamente a todos aqueles que me ajudaram a vencer o desafio de concluir esta dissertação, especialmente os colegas André Caccavo, que me auxiliou na organização do banco de dados; Fábio Lacerda, que além de fornecer importante material para consulta, contribuiu com o seu saber para o entendimento de questões surgidas na elaboração do presente trabalho; João Ferrari e Marcos Soares, que dividiram comigo seus conhecimentos sobre tratamento de dados e construção de variáveis; Marla Luiza Casemiro, Janaina Soares, José Candido e Gabriela Garcia que me ajudaram na tradução de textos; meus companheiros de estudo, Augusto Marques, Cláudio Ruiz, Cristina Bessa, Lara Mendes, Leonardo Bacco, Lindomar Mendes e Raimundo Félix, sem os quais esta luta seria bem mais difícil de ser vencida; e ao meu orientador Tito Belchior.

“O que falta não é demanda. O que falta é demanda solvente”.
Sérgio Darcy diretor do Banco Central do Brasil.

RESUMO

O objetivo deste trabalho é a proposta de um modelo de previsão de insolvência baseado em indicadores contábeis com o uso da análise discriminante. Embora o assunto tenha sido bastante discutido, existe uma necessidade de aprimoramento dos modelos existentes bem como da descoberta de novas variáveis preditoras e técnicas que melhor retratem o comportamento das empresas sob a ótica do risco de crédito.

Com relação as variáveis preditoras da função discriminante, gerada pelo método passo a passo, o trabalho confirmou o poder discriminatório daquelas que evidenciam as decisões financeiras sobre estrutura de ativos (EstA), estrutura de capital (EstC) e a geração de caixa (EBITCT). Outro resultado importante diz respeito ao poder discriminatório da variável representativa do montante dos recursos próprios disponíveis (RCMCPd). Esta variável que é utilizada em estudos sobre solvência de instituições financeiras, apresentou resultados promissores também para empresas não financeiras.

O modelo proposto, estatisticamente significativo, representa, através das suas variáveis independentes, o resultado das decisões das firmas com bom índice de acerto nas predições sobre insolvência.

PALAVRAS-CHAVE: Insolvência, variáveis preditoras, poder discriminatório.

ABSTRACT

The objective of this paper is to propose an insolvency forecast model based on accounting indicators using discriminant analysis. Although this issue had been thoroughly discussed, there is a need of the existing models enhancement as well as the uncovering of new forecasting variables and techniques that would better describe the behavior of corporation through the credit risk prospective.

Regarding the predictives variables of the discriminant function, generated by the stepwise method, the research confirmed the discriminatory power of those variables, which emphasize the financial decisions over asset structure (EstA), capital structure (EstC) and the cash flow related variable (EBITCT). Another important result is related to the discriminatory power of the variable representing the amount of equity(RCMCPd). The variable, which is used on studies related to financial institutions solvency, showed also promising results for non-financial corporations.

The proposed model, which is statistically significant, represents the result of company's decisions showing a good level of prediction on insolvency forecast, through its independent variables.

KEYWORDS: Insolvency, predictives variables, discriminatory power.

SUMÁRIO

1. Introdução	10
2. Revisão Literária e Fundamentação Teórica.....	12
2.1 A importância do crédito	12
2.2. Definição de Crédito.....	15
2.3. Risco de Crédito.....	15
2.3.1. Conceito	15
2.4. Gestão do Risco de Crédito e Criação de Valor.....	16
2.5. Principais Técnicas e Modelos.....	19
2.5.1. Modelos para Avaliação de Portfólios.....	23
2.5.1.1. O Modelo KMV	23
2.5.1.2. O Modelo Creditmetrics	26
2.5.1.3. O Modelo Credit Risk+	30
2.5.1.4. O Modelo CreditPortfolioView.....	33
2.5.2. Modelos para suporte à concessão de crédito	38
2.5.2.1. Estudos sobre Análise Discriminante	38
2.5.2.2 O Modelo de Altman	41
2.5.2.3 O Modelo da Regressão Logística.....	43
3. Metodologia.....	45
3.1 A amostra utilizada.....	45
3.2. A análise discriminante	46
3.2.1 Suposições da análise discriminante	49
3.3. O Evento a ser Modelado	50
3.4. Seleção das Variáveis para estudo.....	52
3.4.1 Variáveis relacionadas à Estrutura de Ativos.....	59
3.4.2 Variáveis relacionadas à Estrutura de Capital ou de Financiamento.....	60
3.4.3. Variáveis relacionadas à geração de caixa ou Retornos	61
3.4.4 Variáveis relacionadas à Liquidez	63
3.4.5 Variáveis relacionadas à eficiência operacional	63
3.5. Transformações de Variáveis	64
3.6. Análise exploratória de dados.....	65
3.7. Nível de significância	66
3.8. Teste de normalidade	67

3.9. Teste de Homogeneidade das variâncias	68
3.10. Teste de Homogeneidade das matrizes de variância-covariância	70
3.11. Seleção das variáveis discriminantes	71
3.12. Estimação da Função Discriminante	72
3.13. Determinação do ponto de corte	75
4. Análise dos Resultados	75
4.1. Dispersão, assimetria e discrepância.....	75
4.2. Teste de Normalidade.....	81
4.2.1. Resultado para a variável EstA:.....	81
4.2.2. Resultado para a variável LogAGRen:.....	82
4.2.3. Resultado para a variável LogACir:	82
4.2.4. Resultado para a variável EstC:	83
4.2.5. Resultado para a variável RCMCPd:	83
4.2.6. Resultado para a variável LogAFRLP:.....	83
4.2.7. Resultado para a variável EBITCT:	84
4.2.8. Resultado para a variável ReCp:	84
4.2.9. Resultado para a variável RORL:	84
4.2.10. Resultado para a variável Liq:	85
4.2.11. Resultado para a variável EVARL:	85
4.2.12. Resultado para a variável QROACir:	86
4.3. Teste de Homogeneidade	86
4.4. Seleção das variáveis discriminantes	87
4.5. Matriz de correlação.....	88
4.6. Quadro resumo dos testes realizados.....	88
4.7. Estimação da Função Discriminante pelo método direto	89
4.8. Determinação do ponto de corte.....	90
4.9. Variância-Covariância entre os grupos	90
4.10. Matriz de Classificação	91
4.11. Estimação da Função Discriminante pelo método passo a passo	91
4.12. Significância da Função Discriminante	93
5. Conclusão	94
6. Bibliografia.....	96

1. Introdução

O gerenciamento de riscos corporativos faz com que as firmas apurem com maior precisão os riscos a que estão expostas e permite que as mesmas aloquem seus recursos com maior eficiência. Sob este prisma, a modelagem de risco de crédito representa ferramenta essencial no direcionamento de suas decisões de investimento e financiamento.

Com a recente desregulamentação global e a crescente mobilidade do capital - consequência das alterações políticas, tecnológicas e, principalmente, econômicas ocorridas, em todo mundo - a oferta de recursos e a demanda por novos produtos financeiros para captação de recursos tiveram forte crescimento, assim como o interesse pelo desenvolvimento da modelagem do risco de crédito.

No Brasil, a estabilidade econômica, a partir da vigência do plano real em 1994, provocou o aumento vertiginoso do volume de operações de crédito entre empresas não financeiras e estimulou o desenvolvimento e a utilização de modelos de classificação do risco de crédito, objetivando minimizar possíveis perdas de faturamento, a consequente diminuição dos fluxos de caixa e do valor presente das firmas.

A literatura correlata apresenta grande quantidade de publicações que descrevem diferentes técnicas e modelos de avaliação do risco de crédito. Estes modelos são, em geral, divididos em dois grupos. Os Modelos quantitativos ancorados em métodos estatísticos, que tem como base características das carteiras ou dados específicos de clientes e os modelos qualitativos, construídos a partir de

informações dos clientes ou fontes externas (centrais de riscos, agências de *rating*¹, etc..).

O modelo proposto neste trabalho é do tipo quantitativo, com utilização da análise discriminante multivariada, tendo como base indicadores contábeis de empresas. O problema a ser resolvido é a estimação da função que melhor discrimine empresas solventes e empresas insolventes.

Os modelos multivariados são por vezes criticados sob a alegação de que são modelos empíricos, desprovidos de teoria. As críticas a estes modelos, principalmente aqueles baseados em dados contábeis, vão desde a não consideração de variáveis ou riscos fora dos balanços até o foco nas relações lineares entre variáveis preditoras e variável dependente. No entanto, diversos estudos que compararam o desempenho de modelos ancorados em análise discriminante com dados contábeis como variáveis explicativas e outras técnicas mostraram resultados que não permitem rejeitar o uso daquelas variáveis como preditoras de um estado de insolvência. Os modelos baseados em dados contábeis com uso da análise discriminante têm apresentado bons índices de acertos nas predições ao longo de muitos períodos como demonstrado no quadro a seguir:

Percentual de acerto de modelos construídos com análise discriminante

Autor	Ano do Desenvolvimento do Modelo	Quantidade de Empresas Analisadas		Setor	Anos Antes da Quebra	Percentual de Acerto (%)
		Boas	Ruins			
Altman	1968	33	33	Diversos	1	93,9
Elizabetsky	1976	274	99	Confecções	1	69
Matias	1978	50	50	Diversos	1	74
Altman	1979	35	23	Diversos	1	80
Pereira	1982	194	61	Indústria	1	74
Pereira	1982	40	18	Comércio	1	79
Barth	2003	726	726	Diversos	1	72

Fontes: Silva, José Pereira. Gestão e Análise de Risco de Crédito, SP, Atlas, 2003

Barth, Nelson Lerner. Inadimplência: Construção de Modelos de Previsão, SP. Nobel, 2004

Caouette et al. Gestão do Risco de Crédito: O próximo grande desafio financeiro

¹ Classificação

Os registros contábeis refletem as ações dos gestores das firmas e estas ações devem ser orientadas pela racionalidade econômica que, segundo a teoria da firma, é a maximização do lucro ou da riqueza do acionista. Maximizar a riqueza do acionista significa alocar recursos em ativos cujo risco seja compatível com seu retorno ou escolher a estrutura ótima de capital ou, ainda, minimizar custos fixos e variáveis. Todas estas ações podem ser extraídas de indicadores contábeis.

Na primeira parte do trabalho, a introdução, é feita a justificativa sobre o estudo do tema, qual o problema associado ao tema e a importância da utilização de indicadores contábeis na construção de modelos de previsão de *default*².

A segunda parte tem como conteúdo a revisão literária e a fundamentação teórica que sustentam a construção do modelo.

Na terceira parte é apresentada a metodologia utilizada com a descrição dos dados e a técnica estatística do modelo.

A quarta parte diz respeito a análise dos resultados e em seguida temos a conclusão do trabalho.

2. Revisão Literária e Fundamentação Teórica

2.1 A importância do crédito

O crédito tem importância fundamental no nível de atividade econômica. Através do processo de transferência de recursos financeiros entre agentes superavitários, doadores de recursos, e deficitários, tomadores de recursos, influencia a formação de capital contribuindo para o crescimento de um país.

² Impossibilidade de pagamento, insolvência.

No comércio e na indústria o crédito facilita a venda de mercadorias, permitindo que os clientes comprem no ato e paguem a prazo. As empresas, ao aumentarem seu volume de vendas, conseguem obter melhor resultado operacional e, não raramente, financeiro. A rentabilidade do capital investido e a liquidez também são beneficiadas.

Um estudo inédito da Serasa³, uma das maiores empresas do mundo em análises e informações para decisões de crédito e apoio a negócios, feito a partir dos balanços de cerca de 36 mil empresas de pequeno, médio e grande porte, da indústria, do comércio e do setor de serviços apontou a força do crédito, principalmente nas empresas não financeiras.

No estudo, onde foram destacados quatro ciclos ocorridos entre 1994 (início da vigência do real) e 2004, a expansão do faturamento real no setor do comércio, bem acima do verificado nos demais setores, se deu pela maior concessão de crédito a clientes desse setor em comparação aos demais. Nesse período, o comércio expandiu o crédito a clientes, em termos reais, em cerca de 239%, enquanto que o mercado como um todo expandiu em cerca de 67%. Alguns fatores foram citados como determinantes desta expansão, principalmente a utilização de novos instrumentos de crédito.

Outro aspecto importante do estudo foi a constatação de que a maior parte das obrigações das empresas foi contraída junto a fornecedores, que nesse período podem ser entendidos como verdadeiros doadores de recursos. Este dado nos remete a importância da aplicação de modelos de avaliação de crédito para

³ SERASA. Estudos Econômicos: Desempenho das Empresas Comerciais Brasileiras de 1994 a 2004. Vendas do Comércio crescem 4,5% em 2004 e expansão do crédito é a maior desde 2000.

empresas não financeiras, pois como visto, elas estão cada vez mais expostas ao risco de inadimplência.

No ano de 2004 a expansão do crédito e a ampliação dos prazos de pagamento possibilitaram a retomada do crescimento, tanto no comércio, que cresceu 4,5%, como para o mercado como um todo, que cresceu 5,5%.

Em relatório mais recente, a Serasa concluiu, com base na análise de 60 mil balanços de empresas de todos os ramos e portes, que de janeiro a junho de 2005 o crédito mercantil, que aparece nos balanços na conta "Fornecedores", totalizou R\$ 185,8 bilhões, valor 21% maior que os R\$ 153,5 bilhões registrados no mesmo período de 2004 e 76,1% superior ao montante registrado em dezembro de 1994. Enquanto isso, o crédito bancário de curto e longo prazo - que aparece na conta "Financiamentos Bancários" - totalizou R\$ 306,8 bilhões e registrou queda real de 11,5% entre junho/2004 e junho/2005.

O estudo também aponta o avanço do endividamento das firmas, medido pela relação dívida total sobre patrimônio líquido, que passou de 70% para 132% no período dezembro/1994 até o final do 1º semestre de 2005. O perfil de endividamento, impulsionado pelo incremento do crédito mercantil, também apresentou mudanças significativas. Estas informações são de extrema importância se avaliarmos que as operações de crédito entre empresas não financeiras nem sempre são avaliadas da mesma forma como fazem as instituições financeiras, especialistas nesta modalidade de operações. O que sugere que as empresas não financeiras que concedem cada vez mais crédito devem eleger como uma de suas prioridades a adoção de técnicas ou modelos para concessão e gerenciamento de seus portfólios de crédito.

2.2. Definição de Crédito

Para PAIVA (1997) a palavra crédito deriva do latim credere, significa acreditar, confiar, ou seja: acreditamos, confiamos nos compromissos de alguém para conosco.

SILVA (2003) diz que esta confiança representa um elemento necessário, porém não suficiente para uma decisão de crédito. Para ele crédito significa a entrega de um bem presente por uma promessa de pagamento futuro. Esta definição serve tanto para o crédito concedido por uma empresa não financeira, onde o bem entregue é representado por um ativo físico, quanto ao crédito bancário no qual o bem entregue é representado por recursos financeiros disponibilizados.

2.3. Risco de Crédito

2.3.1. Conceito

Risco de crédito pode ser definido como uma medida da incerteza relacionada aos retornos esperados em decorrência da incapacidade do tomador de um empréstimo, emissor de um título ou contraparte de um contrato, de cumprir com as suas obrigações, ou de perda em função da degradação da qualidade creditícia do tomador, emissor ou contraparte, que leve a uma queda no valor de mercado das suas obrigações.

O risco de crédito surge toda vez que uma instituição, financeira ou não financeira, concede, ou se compromete a conceder, financiamento sob a forma de empréstimos, vendas à prazo, contratos comerciais (recebíveis, adiantamentos, etc.), investimentos, garantias, cartas de crédito, títulos de renda fixa ou outras formas.

Antonio Marcos Duarte Junior em seu artigo Risco: Definições, Tipos, Medições e Recomendações para seu Gerenciamento, define risco de crédito como a possibilidade de perda de recursos emprestados em função do tomador não honrar seus compromissos. Para ele o risco de crédito, pode ser dividido em três grupos:

- a) Risco do país, como no caso das moratórias de países latino-americanos.
- b) Risco político, quando existem restrições ao fluxo livre de capitais entre países, estados, municípios, etc. Este pode ser originário de golpes militares, novas políticas econômicas, resultados de novas eleições, etc.
- c) Risco da falta de pagamento, quando uma das partes em um contrato não pode mais honrar seus compromissos assumidos (Inadimplência).

2.4. Gestão do Risco de Crédito e Criação de Valor

No passado recente testemunhamos uma verdadeira revolução nas técnicas de gestão do risco. Inicialmente, o processo concentrou-se nas instituições financeiras, mas recentemente o processo vem se espalhando cada vez mais por corporações e demais instituições não financeiras. Um dos focos principais tem sido a análise da insolvência de grandes corporações que possam criar riscos sistêmicos ou de contágio do macro ambiente financeiro.

A preocupação com o risco, em especial aquele derivado das operações de crédito, não é uma novidade. O que há de novo é a cultura e a preocupação de se ter uma gestão integrada do risco, procurando-se identificar e resumir informações consolidadas, dos diversos instrumentos e suas correlações, em algumas poucas métricas que resumem toda a informação. O ilustre professor João Amaro de Matos

em recente evento sobre gestão de risco (São Paulo, maio/2005), discorreu sobre a importância da gestão dos riscos corporativos na geração de valor para a empresa, afirmando que até os anos 90 a gestão de riscos era vista apenas com um seguro, mas recentemente, consubstanciada pela evolução de teorias sobre finanças corporativas, passou a ser vista como fonte de geração de valor. Segundo o professor João Amaro a gestão de riscos pode aumentar o valor da firma, reduzindo custos inesperados, diminuindo a volatilidade dos fluxos de caixa esperados, diminuindo custo de capital e reduzindo custos de agência.

O administrador financeiro, tendo a maximização da riqueza do acionista como meta principal, precisa constantemente tomar decisões dentro de um ambiente dinâmico, onde o risco e a incerteza derivam da conjuntura econômica, política e social. Deve evitar guiar-se somente pela a maximização do lucro como medida de eficiência na gestão financeira da empresa, pois sabe que ela pode trazer sérias conseqüências à qualidade dos resultados e continuidade da empresa a longo-prazo.

Cautela excessiva em nome da qualidade, ou seja, segurança em demasia na alocação dos ativos pode reduzir a rentabilidade, porque ativos seguros tendem a oferecer menor remuneração por não necessitarem compensar o risco.

Emprestar recursos visando apenas o lucro máximo que a operação possa gerar e não receber esses recursos de volta, é caminhar para a insolvência, mas visar somente a segurança do negócio pode reduzir a rentabilidade e, conseqüentemente, dificultar a geração de receitas para satisfazer os custos e, também, o crescimento do capital investido no negócio. Assim, a gestão financeira do crédito deve levar em consideração, na análise da administração de ativos, um fator muito importante e crucial que é o componente risco.

Um dos benefícios de uma boa política de gerenciamento de risco é a potencialização do valor da firma, através da minimização das possíveis perdas na concessão de crédito, principal objetivo deste estudo.

O potencial aumento do valor da firma através de uma política de gerenciamento dos riscos inclui o desenvolvimento de alguns mecanismos ou modelos que façam com que a gestão do risco não só proteja o valor da companhia, mas que de fato faça com que ele aumente.

Com base na equação básica do resultado da firma, Lucro Tributável = receitas – custos = Fluxo de Caixa, e, admitindo-se que o valor da firma é determinado pelo valor presente dos seus fluxos de caixa futuros, podemos inferir que o risco de crédito pode impactar negativamente a receita da empresa, no caso da ocorrência do evento de não pagamento e, conseqüentemente, seu valor presente. Por outro lado, a minimização de perdas derivadas de operações de crédito tem efeitos positivos e imediatos sobre o resultado da empresa e sobre diminuição da volatilidade dos fluxos de caixa futuros, implicando, geralmente, na redução da taxa de retorno exigida pelos investidores e aumento do valor presente, implícito na fórmula a seguir:

$$VP = \frac{LT \times (1 - \tau_c)}{\rho} + (\tau_c \times B) ,$$

onde:

VP = valor presente dos fluxos de caixa ou valor de mercado da firma

LT = lucro tributável ou fluxo de caixa

τ_c = alíquota do imposto incidente sobre o lucro

B = Valor de mercado da dívida da empresa

ρ = taxa de juros ajustada ao risco da empresa.

Alternativamente também podemos verificar o impacto da insolvência no valor da firma utilizando o modelo de Merton (1974) para valoração de ativos. As principais suposições do modelo são:

- Um empréstimo é uma opção (direito sobre um ativo) cujo risco é função da estrutura de capital da empresa;
- A empresa tem uma estrutura de capital simples composta de títulos de dívida de cupom zero e capital próprio.

Para dizer de outra forma:

a) na data $t = 0$

- a empresa tem um patrimônio líquido indicado por PL_0 , uma dívida D_0 e um total de ativos A_0 , onde: $A_0 = PL_0 + D_0$.

b) na data T ($T > 0$) temos que:

- a empresa terá um total de ativos A_T e deverá pagar uma dívida cujo valor será D_T , que, em caso de não pagamento, dará direito aos credores de assumirem a empresa sem nenhum pagamento adicional, implicando que na data T a empresa valerá 0 (zero) para os proprietários, pois nada receberão pela entrega da mesma aos credores em função do *default*.

2.5. Principais Técnicas e Modelos

Para CAQUETTE, ALTMAN e NARAYANAM (1999) os modelos podem ser classificados de acordo com três dimensões diferentes.

Quanto às técnicas utilizadas, que podem ser:

- i) Técnicas econométricas – Análise discriminante (linear e múltipla), análise logit⁴ e análise probit⁵ são algumas das ferramentas utilizadas para modelar a probabilidade de insolvência como variável dependente com variância explicada por um conjunto de variáveis. As variáveis independentes podem ser razões financeiras e outros indicadores microeconômicos, bem como variáveis exógenas usadas para medir condições econômicas.
- ii) Redes Neurais - são sistemas computacionais empregados para tentar imitar o funcionamento do cérebro humano por meio da simulação de uma rede de neurônios interligados. Os mesmos dados utilizados nas técnicas econométricas são trabalhados de forma a formar um modelo de decisão por meio de implementações alternativas de um modelo de tentativa e erro.
- iii) Modelos de Otimização - São técnicas de programação matemática utilizadas para computar os pesos ótimos de atributos de credor e tomador que minimizam o erro do credor e maximizam seus lucros.
- iv) Sistemas especialistas ou baseados em regras – São usadas para imitar de maneira estruturada o processo utilizado por um analista para chegar a uma decisão sobre a concessão de crédito.
- v) Sistemas híbridos que utilizam computação, estimativa e simulação diretas – São modelos ancorados em parte por uma relação causal

⁴ Um modelo logit assume que a probabilidade cumulativa de perda de um empréstimo esteja situada entre 0 e 1, e que a probabilidade de perda seja logisticamente distribuída.

⁵ Um modelo probit assume que a probabilidade cumulativa de perda de um empréstimo esteja situada entre 0 e 1, e que a distribuição de probabilidade seja normal.

direta, onde os parâmetros são determinados por meio de técnicas de estimativa.

Quanto aos domínios os modelos podem relacionados à:

- a) Determinação das probabilidades de inadimplência;
- b) Aprovação de crédito;
- c) Precificação de ativos de crédito;
- d) Estratégias de cobrança.

Quanto aos produtos a que se aplicam podem ser, entre outros:

- I. Construção ou estratificação de carteiras;
- II. Estruturação de operações de financiamento;
- III. Gestão de riscos.

A operação de crédito, por sua vez, pode ser analisada em dois momentos importantes: antes de realizarmos a operação de crédito e no momento seguinte, quando o crédito já foi efetuado.

SECURATO (1998) diz que no primeiro momento, a análise de crédito preocupa-se em examinar as condições do candidato ao crédito e do volume de recursos solicitados, usando ferramentas das mais diversas, como idéias de WESTON (1975), os chamados C's do crédito (condições, caráter, capacidade, capital, conglomerado e colateral).

Além das idéias de WESTON, diversos modelos e técnicas são utilizados para tentar prever a futura capacidade de pagamento do tomador de recursos, constituindo-se em importantes ferramentas auxiliares na tomada de decisão em um mercado cada vez mais concorrido e, sendo assim, podem

proporcionar uma vantagem competitiva a seus usuários. Empréstimos, emissão de títulos e vendas a prazo são produtos que necessitam de modelos de previsão sobre a capacidade de pagamento do tomador de recursos.

FAMA et al (1997), apud SECURATO (1988), declara que são várias as tentativas de obtenção de novos modelos que revelem variáveis que possam explicar e prever falências. As diversas abordagens envolvem em geral modelos que se utilizam dos conhecimentos baseados em Teoria do Caos, Árvore Genética, Regressão Logística, Redes Neurais e outros.

O segundo momento da operação de crédito é após a concessão do mesmo, quando os recursos já estão nas mãos do cliente. Realizada a operação de crédito, ela passa a fazer parte do que denominamos de Carteira de Ativos de Crédito. O tratamento a ser dado a este conjunto de ativos de crédito está baseado na Teoria de Seleção de Carteiras de Markowitz e Sharpe, ou variações do mesmo tema. Dentre as várias formas de aplicarmos a Teoria das Carteiras as carteiras de créditos, uma das propostas mais recentes é o CreditMetrics, apresentado em 1997, pelo J.P. Morgan, onde o problema central está na metodologia para determinação das probabilidades de transformação da qualidade de um crédito dado. A partir destas probabilidades, são estabelecidas as correlações entre os créditos e em seguida calcula-se o valor de risco da carteira de crédito.

Assim, no que diz respeito a finalidade, podemos dividir os modelos em dois grandes grupos:

a) Um grupo onde estão os modelos utilizados para avaliar a capacidade de pagamento de determinado tomador de recursos. Exemplos da análise de regressão, análise de grupamentos, análise discriminante múltipla e análise logit ou

modelo linear de probabilidade. Os dois últimos são aqueles mais apropriados para utilização quando a variável dependente for não métrica (categórica).

b) No outro grupo estão inseridos os modelos desenvolvidos para a administração das carteiras de crédito ou portfólios de ativos.

2.5.1. Modelos para Avaliação de Portfólios

Segundo SAUNDERS (2000), citado por CARNEIRO (2002), os principais modelos para avaliação do risco de portfólio são:

- CreditMetrics – Modelo desenvolvido pelo banco JP Morgan, baseado na abordagem da migração do crédito concedido.
- KMV – Desenvolvido pela KMV Corporation, baseia-se na abordagem estrutural ou avaliação de ativos com base na teoria de Opções.
- CreditRisk+ - Desenvolvido pelo Credit Suisse Financial Products é baseado na abordagem atuarial.
- CreditPortfolioView – Modelo criado pela empresa de consultoria McKinsey é baseado no impacto das variáveis econômicas na capacidade de pagamento dos devedores.

2.5.1.1. O Modelo KMV

O KMV surgiu na década de 80 a partir do desenvolvimento do modelo criado por Kealhofer e Vasicek, que mais tarde associaram-se a McQuown dando origem ao KMV para uso comercial, desenvolvido pela KMV Corporation.

O KMV é utilizado para analisar probabilidades de inadimplência e a distribuição de perdas relacionadas tanto a riscos de *default* quanto de migração do crédito dentro de uma carteira.

Baseado na proposta de Merton (1974) sobre valoração de ativos, o modelo vê um empréstimo como uma opção (direito sobre um ativo) e considera uma empresa, em sua estrutura mais simples, ao longo do tempo, da seguinte forma:

a) na data $t = 0$ (hoje)

- a empresa tem um patrimônio líquido indicado por PL_0 , uma dívida D_0 e um total de ativos A_0 .

b) na data T ($T > 0$) temos que:

- a empresa terá um total de ativos A_T e deverá pagar uma dívida cujo valor será D_T , que, em caso de não pagamento, dará direito aos credores de assumirem a empresa sem nenhum pagamento adicional aos antigos proprietários.

- e supõe-se que durante o período $t = 0$ a $t = T$, a empresa não assume novas dívidas e nem paga dividendos aos proprietários.

Então, utilizando a fórmula de Black e Scholes, calcula-se o valor de PL_0 , ou seja, o prêmio da opção, como segue:

$$PL_0 = A_0 \cdot N(d_1) - D_T e^{-i_T x T} \cdot N(d_2)$$

$$\text{Com, } d_1 = \frac{\ln\left(\frac{A_0 e^{i_F x T}}{D_T}\right)}{\sigma_A \sqrt{T}} + \frac{1}{2} \sigma_A \sqrt{T} \quad \text{e} \quad d_2 = d_1 - \sigma_A \sqrt{T},$$

onde:

- σ_A é a volatilidade da taxa de variação do ativo;
- $N(\cdot)$ é a probabilidade com base na distribuição normal e as demais variáveis já foram explicadas.

A partir da visão da empresa como uma opção de compra e após o desenvolvimento matemático da expressão retro-mencionada tem-se como resultado a função para computar a probabilidade de default (PD):

$$PD = 1 - \frac{PL_0 \cdot e^{i_F \cdot x}}{D_T} \left[k \cdot \frac{\sigma_{PL}}{\sigma_A} - 1 \right],$$

onde:

PD: probabilidade de não pagamento no vencimento T;

D_T : valor da dívida na data T;

PL_0 : valor do patrimônio líquido em $t = 0$;

i_F : taxa livre de risco;

σ_{PL} : volatilidade da taxa de variação do PL;

σ_A : volatilidade da taxa de variação dos ativos da empresa;

k: coeficiente de calibragem do modelo.

A partir deste resultado e considerando a existência de uma taxa de crédito, i_c , a vigorar para a dívida no período T, podemos deduzir que $D_T = D_0 \times e^{i_c T}$, computa-se a probabilidade de ocorrência de não pagamento, como:

$$PD = 1 - \frac{PL_0}{D_T} \times e^{(i_F - i_c)T} \left[k \cdot \frac{\sigma_{PL}}{\sigma_A} - 1 \right],$$

sujeito à:

$$i_F < i_c \text{ e } \left[k \cdot \frac{\sigma_{PL}}{\sigma_A} \right] > 1$$

2.5.1.2. O Modelo Creditmetrics

O Creditmetrics, desenvolvido pelo banco norte-americano J.P. Morgan é uma metodologia baseada na estimativa da distribuição de mudanças futuras no valor de uma carteira de crédito ou títulos em um determinado horizonte de tempo. Estas mudanças de valor são relacionadas, segundo o modelo, à migração da qualidade de crédito do tomador.

CARNEIRO (2002), afirma que o modelo é dividido em duas partes distintas:

Uma parte analítica que inclui:

- i) o cálculo do risco individual;
- ii) contribuições marginais ao risco;
- iii) do valor esperado do portfólio e;

iv) seu desvio padrão

A outra parte do modelo envolve simulação, com o uso de técnicas de Monte Carlo, para derivar a distribuição do valor do portfólio que será utilizada na avaliação da necessidade de capital econômico, segundo a estrutura conceitual do valor em risco (Value at Risk – VaR).

Neste modelo, a volatilidade do valor presente dos fluxos de caixa futuros de um ativo é considerada como uma medida do risco incorporado neste ativo e, para avaliar o risco de um ativo individual, deriva a distribuição do seu valor presente ao final do horizonte de tempo.

No caso específico da migração para a situação de inadimplência, o valor futuro do crédito é definido como o seu valor de recuperação, fixado como um percentual, ou taxa de recuperação, do valor de face do instrumento de dívida.

DERVIZ e KADLCÁKOVÁ (2001), citados por CARNEIRO (2002), indicam que, no momento zero, o valor esperado do crédito ao final do horizonte de tempo, pode ser calculado pela seguinte equação:

$$E[V_h] = \sum_g V_h^g \pi(g),$$

onde:

$E[V_h]$ → valor esperado do crédito, ao final do horizonte de tempo

h → horizonte de tempo escolhido

V_h^g → valor do crédito, caso ocorra uma migração para a classe de risco “g”.

$\pi(g) \rightarrow$ probabilidade de que o crédito migre para a classe de risco “g”

Deste modo, as oscilações do valor futuro do ativo, devido a mudanças na qualidade de crédito, é dada por:

$$\sigma^2 [V_h] = \sum_g (V_h^g - E[V_h])^2 \pi(g)$$

Em complementação, Derviz e Kadlcáková (2001) , citados por CARNEIRO (2002), ainda argumentam que o valor em risco do portfólio tem relação com o emprego de técnicas de agregação. Desse modo, na determinação, por exemplo, do desvio padrão de um portfólio contendo n ativos, tem-se que:

$$\sigma_p^2 = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \sigma_{ij}^2 - (n-2) \sum_{i=1}^n \sigma_i^2$$

onde:

$\sigma_p^2 \rightarrow$ Variância do portfólio

$\sigma_i^2 \rightarrow$ Variâncias dos ativos individuais

$\sigma_{ij}^2 \rightarrow$ Variâncias dos sub-portfólios de dois ativos

O que permite inferir que a informação sobre às variâncias de todos os sub-portfólios de dois ativos tem grande importância na determinação analítica do desvio padrão do portfólio. Sendo assim, é preciso calcular as probabilidades de migração conjunta de todos os pares de ativos, o que implica considerar todas as possíveis combinações de estados (classes de risco) entre os ativos (devedores).

Nesse contexto, assumindo-se que a distribuição de probabilidade conjunta dos retornos padronizados de um par de ativos segue uma distribuição normal bivariada, com correlação ρ é possível determinar as probabilidades de migração conjunta desse par de ativos, integrando a função densidade normal bivariada. Assim, para, por exemplo, um par de ativos referentes devedores classificados nos níveis de riscos BBB e A, tem-se, por exemplo, que a probabilidade conjunta de que ambos os devedores permaneçam em suas classes de risco ao final do horizonte de tempo é dada por:

$$\Pr(Z_{BB} < r_{BBB} < Z_{BBB}, Z_{BBB} < r_A < Z_A) = \int_{Z_{BB}}^{Z_{BBB}} \int_{Z_{BBB}}^{Z_A} f(r_{BBB}, r_A; \rho) dr_{BBB} dr_A$$

onde:

r_{BBB} e r_A → são as classes de risco ao fim do horizonte de tempo

ρ → é a correlação entre os retornos (variações dos ativos)

$f(r_{BBB}, r_A; \rho)$ → é a função da distribuição normal bivariada

No que concerne ao cálculo das correlações, SAUNDERS (2000), citado por CARNEIRO (2002), ressalta que o CreditMetrics utiliza modelos multifatoriais de retornos das ações de devedores individuais. Mais especificamente, o CreditMetrics trabalha a correlação entre os retornos das ações das firmas devedoras como indicativos da correlação entre os retornos dos ativos (não diretamente observáveis). Assume-se que as firmas incluídas no portfólio de crédito estão sujeitas a um conjunto de riscos comuns ou sistêmicos (capturados por meio de uma série de índices de ações específicos de países ou de indústrias com volatilidades e

correlações conhecidas) e a um risco residual, definido como o risco específico da firma, que se presume ser diversificável em um contexto de carteira.

Uma vez concluída a análise de risco no nível de um portfólio de dois ativos (correlações e probabilidades conjuntas), é possível calcular a média e o desvio-padrão e em seguida, utilizando-se a técnica de simulação de Monte Carlo, deriva-se a efetiva distribuição do valor do portfólio, ao final do horizonte de tempo, para fins de determinação do VaR de crédito desse portfólio.

2.5.1.3. O Modelo Credit Risk+

O Credit Risk+ é uma metodologia para calcular a distribuição de possíveis perdas de um portfólio. Desenvolvido pelo Credit Suisse e lançado em 1997, o modelo Credit Risk+ atraiu a atenção de profissionais da área de crédito, acadêmicos e reguladores.

CROUHY, GALLAI e MARK (2004) esclarece que o Credit Risk+ aplica uma estrutura de ciências atuariais à derivação da distribuição de perdas de uma carteira de crédito ou títulos onde somente o risco de insolvência é modelado. A insolvência é modelada como uma variável contínua com uma distribuição de probabilidade caracterizada por uma parametrização específica da média e variância. Em caso de default, a perda é de tamanho fixo, equivalente ao tamanho da dívida, líquida da taxa de recuperação.

O risco de inadimplência, diferentemente do modelo KMV, não é relacionado com a estrutura de capital da firma. Desta forma, um devedor terá uma probabilidade P_A de ser adimplente e $(1 - P_A)$ de ser inadimplente, sendo estas probabilidades

descorrelacionadas de qualquer pressuposto específico sobre as causas ou o momento da inadimplência.

Os empréstimos, componentes de uma carteira de crédito, são agrupados por faixas de exposição, de modo que a distribuição de eventos de não pagamento pode ser derivada por uma distribuição de Poisson com média m (não necessariamente constante), sendo a validade desta aproximação condicionada a que as probabilidades p de default individuais são pequenas e o número N de devedores na carteira é alto.

A implementação do modelo pode ser feita considerando-se as taxas de inadimplência de devedores individuais fixas ou variáveis. Neste último caso, as taxas de *default* são modeladas como variáveis aleatórias contínuas, cujas volatilidades são relacionadas a incerteza do estado futuro dos devedores.

Para CARNEIRO (2002) duas considerações são importantes:

- i) A probabilidade de inadimplência de qualquer devedor, em particular, é pequena e independente das demais probabilidades individuais
- ii) O número de inadimplências, que ocorre em um dado período, é considerado independente do número de inadimplências de qualquer outro período.

Como resultado, na modelagem cujo pressuposto de probabilidades de inadimplência individuais fixas, a variável aleatória relativa ao número de inadimplências no portfólio, ao longo de um dado período, segue uma distribuição de Poisson:

$$P(n) = \frac{\mu^n \cdot e^{-\mu}}{n!} \quad \text{para } n = 0, 1, 2, \dots,$$

Onde:

$n \rightarrow$ Número de inadimplências no período

$\mu \rightarrow$ Número médio de inadimplências no portfólio, por período.

Por exemplo, se considerarmos $\mu=3$, a probabilidade de ocorrência de nenhuma inadimplência ($n = 0$) será:

$$\text{Prob}(0 \text{ default}) = \frac{3^0 e^{-3}}{0!} = 0,05 = 5\%$$

Quando, para fins de modelagem, se considera que as probabilidades de inadimplência (P_A) de cada devedor são fixas, pequenas e independentes tem-se que o número esperado de inadimplência para o portfólio será dado por $\mu = \sum_A P_A$.

E neste caso, a distribuição de probabilidade do número de eventos de inadimplência (n) pode ser aproximada por uma distribuição de Poisson. Portanto, o desvio padrão do índice de inadimplência deverá ter como valor aproximado $\sqrt{\mu}$, onde μ será o índice médio de inadimplência ou, alternativamente, o número médio de eventos de inadimplência no portfólio, ao longo do horizonte de tempo.

Sendo o objetivo central do modelo encontrar a distribuição de probabilidades do nível de perdas do portfólio, em um dado horizonte de tempo, e não somente derivar uma distribuição para o índice de inadimplência, temos que a distribuição das perdas do portfólio será efetivamente diferente da distribuição do número de eventos de inadimplência, porque o montante das perdas depende da exposição a devedores individuais.

O Credit Risk+ apresenta a vantagem de requerer um volume limitado de dados para cálculo, basicamente as exposições individuais e as probabilidades de inadimplência. Desta forma o cálculo da perda em crédito é relativamente simples de ser efetuado.

Dentre as limitações do modelo, deve-se mencionar o fato de que os devedores não são associados a classes de risco e suas características específicas não são determinantes para a determinação de suas probabilidades de inadimplência.

2.5.1.4. O Modelo CreditPortfolioView

CROUHY, GALLAI e MARK (2004) definem o CreditPortfolioView – CPV como um modelo multifatorial utilizado para simular a distribuição condicional de probabilidades conjuntas de inadimplência e probabilidades de migração, para diversos grupos de classes de risco em diferentes setores e países. Estas probabilidades são impactadas, segundo os pressupostos do modelo, pelo comportamento de fatores macroeconômicos como: taxa de desemprego, taxa de variação do PIB, nível das taxas de juros de longo-prazo, taxas de câmbio, gastos governamentais e taxas de poupança agregada. Isto significa que o modelo é ancorado na idéia de que as probabilidades de inadimplência e de migração estão relacionadas com o comportamento da economia. Desta forma, uma piora no cenário econômico implicará em variações negativas na inadimplência e, conseqüentemente, na migração para classes de risco inferiores. Assim os ciclos de crédito seguem os ciclos de negócios com considerável correlação.

Para desenvolvimento do modelo, ocorre uma seqüência de três passos:

- Determinação do índice representativo do estado da economia;
- Determinação das probabilidades de inadimplência;
- Determinação da distribuição de perdas.

O índice macroeconômico, que retrata o estado da economia é determinado pelo modelo univariado autoregressivo de ordem 2 (AR2) a seguir:

$$Y_{j,t} = \beta_{j,0} + \beta_{j,1}X_{j,1,t} + \beta_{j,2}X_{j,2,t} + \dots + \beta_{j,m}X_{j,m,t} + v_{j,t}$$

Onde:

$Y_{j,t}$ = valor do índice, no período t , para o j -ésimo segmento.

$\beta_j = (\beta_{j,0}, \beta_{j,1}, \beta_{j,2}, \dots, \beta_{j,m})$ são os coeficientes a serem estimados para o j -ésimo segmento a que pertencem as firmas.

$X_{j,t} = (X_{j,1,t}, X_{j,2,t}, \dots, X_{j,m,t})$ são os valores das variáveis macroeconômicas (crescimento do PIB, desemprego, etc.), no período t , para o determinado país considerado no modelo.

$v_{j,t}$, independente de $X_{j,t}$ e normalmente distribuído, é o termo que denota o erro de estimativa e indica que o índice macroeconômico $Y_{j,t}$ também é impulsionado por inovações ou choques aleatórios (não sistemáticos) ao sistema econômico.

Em seguida as probabilidades de inadimplência são modeladas como uma função logit, onde a variável independente é um índice específico que depende de variáveis macroeconômicas correntes e defasadas como segue:

$$P_{j,t} = \frac{1}{1 + e^{-Y_{j,t}}},$$

Sendo:

$P_{j,t}$ = probabilidade de inadimplência condicional, no período t , para os devedores de uma classe de risco, no segmento j .

$Y_{j,t}$ = valor do índice macroeconômico representativo do estado da economia

Assim, a probabilidade $P_{j,t}$ e o índice $Y_{j,t}$ podem ser definidos para o setor específico e , como consequência, os coeficientes β_j serão ajustados de acordo com a definição do tipo de segmento para qual se deseja efetuar o cálculo.

Combinando-se as equações anteriores, computam-se as probabilidades de inadimplência para todos os j segmentos, levando-se em conta uma dada realização das inovações ou choques aleatórios no sistema econômico como um todo (ν) e dos choques específicos de cada variável macroeconômica (ε). Esse cálculo depende, portanto, da solução do seguinte sistema de equações:

$$P_{j,t} = \frac{1}{1 + e^{-Y_{j,t}}}$$

$$Y_{j,t} = \beta_{j,0} + \beta_{j,1}X_{j,1,t} + \beta_{j,2}X_{j,2,t} + \dots + \beta_{j,m}X_{j,m,t} + \varepsilon_{j,t}$$

$$X_{j,i,t} = \gamma_{j,i,0} + \gamma_{j,i,1}X_{j,i,t-1} + \gamma_{j,i,2}X_{j,i,t-2} + \varepsilon_{j,i,t}$$

$$E_t = \begin{bmatrix} \nu_t \\ \varepsilon_t \end{bmatrix} \sim N(0, \Sigma) \quad \text{com} \quad \Sigma = \begin{bmatrix} \Sigma_\nu & \Sigma_{\nu,\varepsilon} \\ \Sigma_{\varepsilon,\nu} & \Sigma_\varepsilon \end{bmatrix},$$

Onde:

E_t = o vetor de inovações (choques) que afetam o sistema de equações.

Σ = a matriz de covariância dos erros.

Em seguida as variâncias e co-variâncias de ν_t e ε_t são computadas a partir da matriz Σ , decomposta utilizando-se a decomposição de Cholesky, onde $\Sigma = AA'$.

A simulação de choques para derivar a distribuição de probabilidades de inadimplência pode ser implementados multiplicando-se a matriz A' por um gerador de números aleatórios - um vetor de variáveis aleatórias dado por $Z_t \sim N(0, I)$, onde cada componente é normalmente distribuído $N(0,1)$. A seguir, calcula-se $E_t = A'Z_t$ – o vetor de choques – e deriva-se os correspondentes valores para $Y_{j,t}$ e $P_{j,t}$, considerando-se as realizações desses termos de erro.

WILSON (1997) , citado por CARNEIRO (2002), faz uma observação final que é tanto intuitiva quanto empiricamente verificável: Existe vinculação entre as migrações de classes de riscos e a macroeconomia. O significado desta observação é que a probabilidade de default e também a de migração para classes de risco inferiores são afetadas pelo comportamento da economia.

O CPV, baseado na correlação entre as taxas de inadimplência e a migração de crédito, computa uma matriz de migração condicional à atual taxa de inadimplência. Isto implica que se a real probabilidade de inadimplência de devedores classificados com os piores riscos for maior que média histórica – situação mais provável de acontecer em períodos de recessão – então a probabilidade de mudança para classes de riscos inferiores tende a ser maior, enquanto a probabilidade de migração para classes de riscos superiores tende a cair. O oposto é verdadeiro para períodos de crescimento econômico. Assim, tem-se que:

$$\frac{SDP_t}{\phi SDP} > 1 \quad \text{quando a economia estiver em recessão e;}$$

$$\frac{SDP_t}{\phi SDP} < 1 \quad \text{quando a economia estiver em crescimento,}$$

Sendo:

- SDP_t a probabilidade de inadimplência simulada, para devedores classificados nos níveis dos piores riscos ($P_{j,t}$).
- ϕSDP a probabilidade de inadimplência incondicional (baseada na média histórica), para os devedores com risco especulativo.

Os quocientes $\frac{SDP_t}{\phi SDP} > 1$ e $\frac{SDP_t}{\phi SDP} < 1$ são utilizados, segundo a proposta do CPV, para ajustar as probabilidades de migração indicadas em uma matriz de transição incondicional de Markov, ϕM , computada a partir dos dados calculados por uma agência *rating* ou de dados históricos internos, que passará a ser denotada por. O resultado do ajuste é um deslocamento da massa de probabilidades em direção às classes inferiores de risco e à classe indicativa de inadimplência, quando a relação $SDP_t / \phi SDP$ for maior que 1, e vice-versa quando essa relação for menor que 1. Assim, considerando que $SDP_t = P_{j,t}$, pode-se gerar uma matriz de migração condicional, para múltiplos períodos, utilizando-se a seguinte equação:

$$M_T = \prod_{t=1, \dots, T} M(P_{j,t} / \phi SDP).$$

CROUHY, GALLAI e MARK (2004), salientam que é possível, utilizando a metodologia de Monte Carlo, simular inúmeras vezes a matriz de migração condicional acima indicada, gerando-se uma distribuição das probabilidades cumulativas de migração condicional, para qualquer classe de risco e ao longo de qualquer período.

Desta forma, como destaca Saunders (2000), citado por CARNEIRO (2002), o modelo produz diferentes matrizes de migração, refletindo o efeito simulado dos choques macroeconômicos sobre as probabilidades de migração. Com base nesses

resultados, pode-se calcular um VaR de crédito que seja sensível à influência do ciclo econômico.

2.5.2. Modelos para suporte à concessão de crédito

2.5.2.1. Estudos sobre Análise Discriminante

Até 1980, segundo BACK et al (1996), os principais modelos para previsão de inadimplência eram baseados na técnica de análise discriminante. Em 1980 surgiram os modelos baseados na análise logística e logo após outras técnicas foram empregadas no desenvolvimento de modelos de previsão de falência, como as técnicas de redes neurais e algoritmos genéticos.

BACK et al (1996), utilizando dados contábeis de firmas finlandesas do período 1986 a 1989, aplicaram e compararam modelos baseados nestas técnicas e chegaram aos seguintes resultados:

- 1) As diferenças entre os métodos ou técnicas utilizadas afetam a escolha do número de variáveis independentes;
- 2) O conteúdo de informações dos modelos muda devido as variáveis que estão medindo eventos macroeconômicos (taxa de juros, cambio, PIB, etc..) ou microeconômicos (dados contábeis);
- 3) A precisão dos métodos é diferente;
- 4) Os percentuais de Erro Tipo – I (classificar um cliente como provável inadimplente quando suas condições de pagamento são boas) e Erro Tipo – II (classificar um cliente como bom pagador

quando na verdade a probabilidade de iliquidez é significativa) foram sintetizados na tabela a seguir:

Anos Antes da quebra	Erro Tipo I			Erro Tipo II			Erro Total		
	Análise Discriminante (%)	Análise Logística (%)	Redes Neurais (%)	Análise Discriminante (%)	Análise Logística (%)	Redes Neurais (%)	Análise Discriminante (%)	Análise Logística (%)	Redes Neurais (%)
1	13,51	13,51	5,26	16,22	13,51	0,00	14,86	3,51	2,70
2	24,32	27,03	26,32	18,92	29,73	27,78	21,62	28,40	27,03
3	16,22	16,22	5,26	37,84	35,14	27,78	27,03	25,70	16,22

O menor percentual de erro na predição de dificuldade de pagamento, 1 (um) antes da ocorrência do evento, ficou com modelo de redes neurais. Dois anos antes, o melhor modelo foi aquele baseado na análise discriminante e para três anos antes, novamente, o modelo construído a partir da técnica de redes neurais foi o melhor.

BARTH (2004), usando uma mostra de 1452 empresas brasileiras, comparou o desempenho de métodos baseados em análise discriminante, regressão logística, algoritmos genéticos e redes neurais. O desempenho obtido com análise discriminante foi superior ao obtido com algoritmo genético (ambos geradores de funções discriminantes lineares) e os acertos conseguidos com o uso de redes neurais foram superiores ao da regressão logística.

Na comparação entre os quatro modelos, levando-se em consideração o maior percentual de acerto, o modelo baseado em redes neurais mostrou-se mais adequado. Porém, se a interpretabilidade do modelo for considerado um quesito importante para a escolha, a análise discriminante linear será mais apropriada. Este fato mostra que um modelo que tem por objeto a discriminação entre grupos não pode ser escolhido somente com base em um único critério, pois os modelos têm vantagens e desvantagens que devem ser avaliadas na decisão. No estudo de BARTH foram levados em consideração, na comparação dos modelos, o percentual de acerto, o tempo de processamento e a facilidade de interpretação.

BARTH (2004), alerta que alguns pressupostos são importantes para uso da técnica da análise discriminante, combinação linear entre variáveis independentes. Uma destas premissas é a condição suficiente, mas não necessária, de normalidade na distribuição das variáveis utilizadas. Como é comum o uso de variáveis contínuas, que nem sempre apresentam distribuição normal, e de variáveis categóricas, como sexo, região geográfica, área de atuação, etc., em que, com certeza, não existe normalidade, isto implica que o modelo poderá não ser suficientemente robusto, enfrentando reservas no seu uso. A resistência pode ser minimizada com a determinação dos pesos de cada variável e um ponto de corte.

A acurácia do modelo também pode ser comprometida na falta de igualdade das variâncias e covariâncias nos grupos. Um teste para verificar a igualdade das matrizes de covariância, sugerido por BARTH (2004), é o M de Box.

Outra premissa que não pode faltar é a de linearidade nas relações entre as variáveis.

LO (1986) produziu um trabalho onde comparou a análise discriminante com a análise logística e concluiu, após um teste de especificação para a análise de falência de corporações, que a hipótese de equivalência entre a análise discriminante e logit não pode ser rejeitada. O resultado do trabalho indicou, ainda, que, para fins de classificação, a não-normalidade pode ser menos problemática do que sugeriu estudos anteriores.

McFadden, citado por LO (1986), confirma que, embora distintos, esses dois métodos são muito próximos. Em particular, se y é uma variável discreta e X um vetor de variáveis explicativas contínuas, a análise logit e a análise discriminante são meios alternativos de caracterizar a distribuição conjunta de (y, X) . A análise discriminante dá ênfase na distribuição de X condicionada em y e, na prática, é

quase sempre suposto que a distribuição de X/y é normal com matriz de covariância comum entre os y 's.

2.5.2.2 O Modelo de Altman

CAOQUETTE, ALTMAN e NARAYANAM (1999) descrevem os modelos de Altman (Escore-Z e sua variação ZETA) como abordagens multivariadas construídas com base em valores de nível de índices e categorias. O risco de crédito é derivado a partir do computo destes valores, combinados e ajustados, e demonstrado em uma medida, o escore de risco de crédito.

O escore de risco de crédito tem como proposta a discriminação das empresas em dois grupos:

- i) empresas boas, cuja probabilidade de não pagamento é pequena e;
- ii) empresas ruins, que tem grande probabilidade de não honrarem seus compromissos financeiros.

O modelo foi construído com base na técnica da análise discriminante múltipla, objetivando analisar um conjunto de variáveis para maximizar a variância entre grupos ao mesmo tempo em que minimiza a variância interna destes grupos.

A partir da avaliação de uma lista de 22 variáveis, extraídas de demonstrativos contábeis, Altman construiu, em 1968, a seguinte função discriminatória:

$$Z = 0,012X_1 + 0,014X_2 + 0,033X_3 + 0,006X_4 + 0,999X_5,$$

onde:

Z = Escore ou variável dependente,

As variáveis independentes ou explicativas foram:

$$a) X_1 = \frac{\text{capital de giro}}{\text{ativo total}}$$

$$b) X_2 = \frac{\text{lucros retidos}}{\text{ativo total}}$$

$$c) X_3 = \frac{\text{Lucro antes dos Juros e Impostos}}{\text{ativo total}}$$

$$d) X_4 = \frac{\text{valor de mercado do patrimonio liquido}}{\text{valor nominal do passivo}}$$

$$e) X_5 = \frac{\text{vendas}}{\text{ativo total}}$$

O modelo foi derivado de uma amostra de 66 empresas americanas, sendo 33 concordatárias e 33 não concordatárias, no período de 1946 a 1965. As empresas, tanto as não concordatárias (boas) quanto as concordatárias (ruins), foram separadas, previamente, por tamanho e setor econômico.

Todas as variáveis, com exceção de X_5 , apresentaram F satisfatório ao nível de significância de 1%.

Com referência a contribuição relativa (peso) de cada variável na discriminação dos grupos, a variável X_5 mostrou ser a mais importante, seguida por X_3 .

A função mostrou-se eficaz na classificação de 93,9% das empresas um ano antes do evento da concordata. O erro tipo I (classificar empresas concordatárias como não concordatárias) foi de 6%, e o erro tipo II (classificar empresas não concordatárias como concordatárias) foi de 3%. Dois anos antes do evento da concordata, o modelo classificou corretamente 72% dos casos.

CAOQUETTE, ALTMAN e NARAYANAM (1999), relatam que Altman avaliou serem apropriados, no modelo, a determinação de um valor limite inferior (1,81) para classificar as empresas que quebram e um superior (2,99) para as firmas que não quebram. Qualquer escore no intervalo destes limites estaria em uma zona de dúvida, e não seria conclusivo para discriminar os grupos.

Posteriormente Altman reviu o modelo Escore-Z original, substituindo o valor de mercado, na variável, X_4 pelo valor nominal do patrimônio líquido. O objetivo foi adequar o modelo para avaliar empresas de capital fechado. Como resultado, a função discriminante passou a ser:

$$Z = 0,717X_1 + 0,847X_2 + 3,107X_3 + 0,420X_4 + 0,998X_5$$

Além desta revisão, Altman alterou o modelo para melhorar a avaliação de empresas Não-Fabris e, em 1977, efetuou novas correções para possibilitar a análise de empresas de varejo além de adequar o modelo as mudanças de padrão das demonstrações contábeis. O novo modelo, denominado ZETA, com sete variáveis explicativas provou ser mais confiável em diversos procedimentos de validação e mais preciso que o modelo Escore-Z.

2.5.2.3 O Modelo da Regressão Logística

A análise logit ou regressão logística, também conhecida como modelo linear de probabilidade, pode ser visto como uma combinação da regressão múltipla com a análise discriminante múltipla. A similaridade com a regressão múltipla está no sentido em que uma ou mais variáveis independentes são utilizadas para prever ou explicar uma variável dependente. O que a diferencia da regressão múltipla é o fato da variável dependente ser não métrica, como no caso da análise discriminante.

BARTH (2004) mostra que o modelo de previsão baseado na regressão logística assume a validade da seguinte relação matemática:

$$\ln\left[\frac{p}{1-p}\right] = b_0 + b_1 \cdot X_1 + b_2 \cdot X_2 + b_3 \cdot X_3 + \dots + b_n \cdot X_n$$

ou
$$p = \frac{1}{1 + e^{-(b_0 + b_1 X_1 + \dots + b_n X_n)}}$$
,

que pode ser escrito:
$$p = \frac{1}{1 + e^{-y}}$$
,

com $b_0 + b_1 \cdot X_1 + \dots + b_n \cdot X_n = y$ e $0 \leq p \leq 1$.

os termos utilizados são definidos como:

p = probabilidade de solvência;

$(1 - p)$ = probabilidade de insolvência;

X_i = variáveis preditoras (métricas ou dummy variables);

b_i = coeficientes a serem atribuídos a cada uma das variáveis X_i .

BARTH (2004) diz que, após selecionadas as variáveis (X_i) que comporão o modelo e os seus respectivos coeficientes ou pesos (b_i), faz-se necessário definir uma regra de classificação ou discriminação dos grupos de prováveis tomadores de recursos, determinado um ponto de corte (limite para classificar ou discriminar os grupos). Se $p <$ ponto de corte, a regra é classificar este potencial tomador de recursos no grupo dos potenciais inadimplentes e quando $p >$ ponto de corte o tomador será classificado no grupo dos potenciais adimplentes.

3. Metodologia

3.1 A amostra utilizada

A amostra utilizada neste trabalho é composta de informações econômico-financeiras de 116 empresas de capital aberto de 17 setores diferentes, no período 1994 a 2003, coletadas do banco de dados do Sistema de Análise de Balanços de Empresas - SABE, construído pelo Instituto Brasileiro do Mercado de Capitais – IBMEC. Dentro deste universo, as empresas que se encontravam no estado de insolvência, definido no item seguinte, foram selecionadas como ruins. Os indicadores contábeis das empresas ruins foram extraídos dos demonstrativos contábeis referentes a um ano antes da entrada no estado de insolvência e as informações das empresas boas, do mesmo setor, na mesma data. Assim, se uma empresa entrou no estado de insolvência em 1996 foram extraídos, para este estudo, os dados do seu balanço patrimonial de 1995 e para efeito de comparação foram utilizados os dados de uma empresa boa, que não entrou no estado de insolvência, do mesmo setor, da mesma data, 1995.

A partir desta primeira seleção foram formadas duas amostras.

Uma amostra de desenvolvimento (tabela 1, anexa), composta de 35 empresas que entraram no estado de insolvência, empresas ruins, e igual número de empresas que não entraram no estado de insolvência, empresas boas, do mesmo setor ou com ativos equivalentes.

Este tipo de amostra é denominado amostra emparelhada e é constituída pelos elementos que possuem fatores ou fontes de variabilidade (no caso, o setor ou volume de ativos) que nada tem a ver, diretamente, com o estudo, mas que podem interferir nos resultados esperados.

Uma amostra de validação ou controle (Tabela 2, anexa), contendo 23 empresas ruins e igual número de empresas boas, selecionadas pelos mesmos critérios da amostra de desenvolvimento.

3.2. A análise discriminante

Para HAIR et al (2005) A análise discriminante múltipla é a técnica multivariada adequada para estudar problemas onde a variável estatística (combinação linear de variáveis com pesos determinados empiricamente) é dicotômica e, portanto, não métrica. Então ela é indicada para construir modelos de previsão de inadimplência, cujo objetivo principal é a classificação de um aspirante a crédito em um determinado grupo de:

- a) Provável adimplente (solvente) ou;
- b) Provável inadimplente (insolvente).

A técnica procura, basicamente, responder se um elemento pertence ou não a uma determinada categoria. Tratando-se da análise de risco de crédito, a análise discriminante, ou especificamente a função discriminante, indicará se uma empresa pertence a um grupo de firmas solventes ou ao conjunto das insolventes.

A variável dependente ou variável estatística é o constructo resultante da combinação linear de uma ou mais variáveis independentes. No caso da existência de somente uma variável independente temos a análise univariada e quando existe um número maior de variáveis independentes temos a análise discriminante multivariada.

O valor previsto da função da discriminante é o escore discriminante, o qual é calculado para cada objeto (pessoa, empresa ou produto) na análise. A função discriminante tem a seguinte forma:

$$Z = a + W_1 \cdot X_1 + W_2 \cdot X_2 + W_3 \cdot X_3 + \dots + W_n \cdot X_n$$

Onde:

Z = escore discriminante ou categoria

a = intercepto

W_i = Peso ou coeficiente discriminante para a variável i

X_i = Variável independente i

Os objetivos da análise discriminante são:

- a) Identificação das variáveis que melhor diferenciam ou separam grupos de indivíduos estruturalmente diferentes e mutuamente exclusivos;
- b) Estimação dos pesos ou coeficientes da função discriminante;
- c) A utilização das variáveis e dos coeficientes para estimar um “índice” ou função discriminante que represente as formas entre os grupos ou classes;
- d) A utilização desta função para classificar *à priori* novos indivíduos nos grupos.

As variáveis independentes relevantes, formadoras da função discriminante, são obtidas por recurso à estatística lâmbda (λ) de Wilks.

A estatística para cada uma das variáveis, segundo MAROCO (2003), é dada por:

$$\lambda = \frac{SQE}{SQT}$$

Sendo:

a) $SQE = \sum (y_i - \bar{y})^2$ = soma dos quadrados dos erros dentro dos grupos.

b) $SQT = \sum (y_i - \hat{y}_i)^2$ = soma dos quadrados totais.

c) y = variável sob estudo

d) \bar{y} = valor médio de y

e) \hat{y} = valor estimado de y

Os pesos ou coeficientes $w_{i1}, w_{i2}, \dots, w_{ip}$ são estimados de modo que a variabilidade dos escores (D_i) da função discriminante seja máxima entre os grupos e mínima dentro dos grupos. Eles representam uma medida relativa da importância das variáveis originais na função estimada. Quanto maior for o coeficiente das variáveis independentes, maior será a sua contribuição na discriminação entre os grupos, passo importante para interpretação e análise do modelo.

Desta forma, dadas p -variáveis e g grupos é possível estabelecer $m = \min(g - 1; p)$ funções discriminantes que são combinações lineares das p -variáveis, tal que:

$$D_i = w_{i1}X_1 + w_{i2}X_2 + \dots + w_{ip}X_p, \text{ com } i = 1, \dots, m$$

O nível de significância da função é estimado com base em uma transformação qui-quadrado da estatística (λ) de Wilks.

A classificação de indivíduos em classes utilizadas para estimar a função discriminante é procedida de modo a que cada indivíduo seja inserido no grupo cujo centróide (valor médio para os escores discriminantes de todos os elementos, em uma dada categoria ou grupo) se encontra mais próximo.

O ponto de corte ou zona de fronteira é dado por:

$$f = \frac{n_1 \bar{d}_1 + n_2 \bar{d}_2}{n_1 + n_2},$$

onde:

\bar{d}_1 e \bar{d}_2 são as médias (centróides) da função discriminante nos grupos 1 e 2 e n_1 e n_2 são as dimensões (números de indivíduos) destes grupos.

Assim um determinado indivíduo pertencerá ao grupo 1 se o seu escore, D_i , for maior que f do contrário será classificado no grupo 2.

3.2.1 Suposições da análise discriminante

Para HAIR et al (2005), certas condições são requeridas para a aplicação da análise discriminante. As suposições mais importantes são a de normalidade das variáveis independentes e igualdade nas matrizes de dispersão e covariância dos grupos. A falta de normalidade pode causar problemas na estimação da função discriminante e matrizes de covariâncias desiguais podem afetar negativamente o processo de classificação.

Uma outra característica dos dados que pode comprometer os resultados é a multicolinearidade entre variáveis independentes. Esta característica indica se duas ou mais variáveis são correlacionadas, de maneira que uma variável pode ser explicada por outra, acrescentando pouco ao poder elucidativo do conjunto como um todo.

O pressuposto de linearidade das relações entre as variáveis está implícito na função discriminante, pois relações não lineares não são refletidas na função, a menos que transformações específicas de variáveis sejam executadas para representar efeitos não lineares.

3.3. O Evento a ser Modelado

O evento a ser modelado neste trabalho é o estado de insolvência ou iliquidez, declarado ou presumido, um ano antes da sua ocorrência.

Insolvência, palavra derivada do latim *solvere*, regido pela negativa *in*, expressa o estado em que se encontra a pessoa, física ou jurídica, de não poder solver ou não pode pagar suas dívidas.

Na visão jurídica é a situação em que o ativo do devedor é insuficiente para fazer face ao passivo, isto é, quando há um excedente de passivo em relação ao seu ativo patrimonial.

Nos meios comerciais e financeiros a insolvência significa falência ou concordata. Essas situações, concordata ou falência, são expressamente declaradas pela própria empresa ou por um credor. No entanto existem situações, não raras, exteriorizadas nos demonstrativos contábeis, em que a empresa encontra-se no estado de insolvência, mas não a declara. Neste sentido, vale conhecer os

ensinamentos do Ilustre Professor Rubens Requião (1998), em sua obra Curso de Direito Falimentar, onde diz que:

“A insolvência, conceitualmente é um fato que, geralmente, se infere da insuficiência do patrimônio do devedor para o pagamento de suas dívidas, sendo que esse estado tanto pode ser confessado pelo empresário comercial, como pode ser presumido por atos que exteriorizem a ruína da empresa.”

LEV (1978), citado por GIMENES & OPAZO (2001), afirma que o estado de insolvência de uma empresa pode ocorrer quando esta se vê incapacitada para pagar suas obrigações financeiras no vencimento, bem como quando seus ativos forem inferiores aos seus passivos.

Então, o estado de insolvência pode ser declarado, casos da concordata e falência ou presumido, situação em que os demonstrativos contábeis mostram claramente que total dos ativos é menor que o valor das dívidas, como demonstrado a seguir.

Seja A_t o valor total dos ativos de uma empresa no tempo t ; D_t o valor das dívidas e PL_t o valor do capital próprio. Se:

i) $A_t = D_t + PL_t$, com $D_t \geq 0$ e $PL_t \geq 0$, dizemos que a empresa é solvente, pois $A_t \geq D_t$;

ii) $A_t = D_t + PL_t$, com $D_t \geq 0$ e $PL_t < 0$, dizemos que a empresa está insolvente, pois $A_t < D_t$.

O objetivo deste estudo é modelar o comportamento das empresas antes da entrada no estado de insolvência, declarado (concordata ou falência) ou presumido

(passivos > ativos) e, a partir daí, construir um modelo que possibilite a previsão deste evento.

3.4. Seleção das Variáveis para estudo

SANVICENTE e MINARDI (1998) desenvolveram trabalho exploratório, tendo como objetivo principal a identificação de índices contábeis mais significativos para prever concordatas de empresas no Brasil e como objetivo secundário, testar a crença do mercado de que demonstrações contábeis não fornecem boa informação para análise de crédito de empresas. A técnica estatística empregada foi a análise discriminante e os índices contábeis analisados foram selecionados com base em trabalhos de Edward Altman (1968 e 1977) e dinâmica de overtrading discutida por Assaf Neto e Tibúrcio Silva (1995). As variáveis analisadas foram:

$$X_1: (\text{ativo circulante} - \text{passivo total}) / \text{ativo total}$$

$$X_2: (\text{patrimônio líquido} - \text{capital social}) / \text{ativo total}$$

$$X_3: (\text{lucro operacional} + \text{resultado financeiro}) / \text{ativo total}$$

$$X_4: \text{valor contábil do patrimônio líquido} / \text{valor contábil do exigível total}$$

$$X_5: \text{receita líquida} / \text{ativo total}$$

$$X_6: (\text{ativo circ. operacional} - \text{passivo circ. operacional}) / \text{ativo total}$$

$$X_7: (\text{ativo circ. financeiro} - \text{passivo circ. financeiro}) / \text{ativo total}$$

$$X_8: \text{lucro operacional antes de juros e impostos} / \text{despesas financeiras}$$

$$X_9: (\text{LAJIR} + \text{depreciação} - \text{investimento em capital de giro}) / \text{ativo total}$$

X_{10} : investimento permanente / ativo total

X_{11} : impostos / ativo total

X_{12} : variação do disponível / ativo total

X_{13} : pagamento líquido aos credores / ativo total

X_{14} : pagamento líquido aos acionistas / ativo total

SANVICENTE e MINARDI (1998) relatam que as cinco primeiras variáveis foram as mesmas testadas no Brasil por Altman, Baidya e Dias em 1977 e por Sanvicente e Bader em 1996. As variáveis X_6 e X_7 referem-se a medidas de liquidez que controlam o fenômeno de overtrading (efeito tesoura) citado por Assaf Neto e Tiburcio Silva. A variável X_8 corresponde ao índice de cobertura de juros, e é uma das variáveis consideradas na concessão de ratings pela agência Standard & Poor's (1997). As variáveis X_9 a X_{14} foram sugeridas por Mossman, Bell, Swartz e Turtle (1998) em um modelo discriminante baseado em dados de fluxo de caixa.

O estudo concluiu que indicadores contábeis com maior poder de previsão de insolvência foram os índices de liquidez, X_1 , seguidos por indicadores de lucros retidos X_2 , rentabilidade X_3 , endividamento X_4 e cobertura de juros X_8 que aumentaram o poder de previsão do modelo. O indicador de giro do ativo, X_5 , apresentou sinal contrario a intuição e contribuiu negativamente para o poder de previsão da função discriminante.

Altman em seu modelo ZETA utilizou sete variáveis:

X_1 : Lucro antes dos juros e imposto / ativo total

X_2 : Medida normalizada do erro padrão de estimativa em torno de uma tendência de cinco a dez anos para X_1

X_3 : Lucro antes dos juros e impostos / total de juros

X_4 : Lucro retidos / ativo total

X_5 : Ativo Circulante / Passivo Circulante

X_6 : Valor de mercado do Patrimônio Líquido / Capital social

X_7 : \ln (ativo total)

O modelo mostrou-se desempenho superior ao modelo Escore-Z original e, também, ao modificado.

GLEN (2004), em um estudo com 6.000 firmas de 41 países, destacou a significância da relação das dívidas financeiras com a insolvência das empresas. Ele construiu um indicador denominado ICR⁶, índice de cobertura de juros, e concluiu que diversos fatores contribuem para determinar a capacidade das firmas cumprirem com suas obrigações financeiras. A expressão matemática a seguir é a síntese do trabalho.

$$ICR_{ykt} = \alpha + \beta_1 CPI_{kt} + \beta_2 IntRate_{kt} + \beta_3 GDP\%_{kt} + \beta_4 IntCV_{it} + \beta_5 EBITDACV_{it} + \beta_6 TLTASS_{it} + \beta_7 CATASS_{it} + \beta_8 LNTASS_{it} + \gamma Sector_j + \delta Country_k + \varepsilon_{ijkt}$$

Onde:

CPI – taxa de inflação

IntRate – taxa de juros

GDP% - taxa de crescimento econômico

⁶ Interest Coverage Ratio - relação do lucro antes dos juros, impostos e depreciação e a despesa com juros.

IntCV – variação das despesas com juros

EBITDACV – variação do EBITDA⁷

LTASS - relação das responsabilidades totais com os recursos totais

CATASS - relação de recursos atuais (circulante) e os recursos totais

lnTASS - logaritmo natural dos recursos totais

Sector – setor específico da empresa

Country – risco país

Segundo GLEN (2004) dois fatores específicos da empresa, IntCV e EBITDACV, podem ser usados como medida do nível de risco de insolvência da firma. Em particular o EBITDA, considerado em seu trabalho como uma *proxy*⁸ de fluxo de caixa, tem importante papel no movimento do ICR.

Dividindo-se o EBITDA pelo Ativo Total temos como resultado o retorno do ativo que, por sua vez, pode ser decomposto em margem de lucro e o giro do ativo, então:

$$\frac{EBITDA}{ATIVOTOTAL} = \frac{EBITDA}{VENDAS} \times \frac{VENDAS}{ATIVOTOTAL}$$

Isto nos diz que a margem de lucro ($\frac{EBITDA}{VENDAS}$) e o giro do ativo ($\frac{VENDAS}{ATIVOTOTAL}$) têm papel fundamental na geração do fluxo de dinheiro para a empresa e, conseqüentemente sua liquidez.

⁷ Earn Before Interesting, Taxes, Depreciation and Amortization, lucro antes dos juros, impostos e depreciação.

⁸ Representante.

O EBITDA, considerado aqui no estudo de GLEN, assemelha-se ao numerador das variáveis independentes X_1 e X_3 , Lucro antes dos juros e impostos, usadas no modelo ZETA desenvolvido por Altman (1977) e indica a importância da avaliação da capacidade de geração de caixa da empresa e sua estreita correlação com a capacidade de pagamento.

GITMAN (2003) diz que a quebra de uma empresa pode ter diversas causas que vão desde a má administração, evidenciada por decisões incorretas, a variações no nível de atividade econômica. Segundo este autor, uma empresa que apura, sistematicamente, resultados insuficientes para cobrir seu custo de capital caminha normalmente para a quebra. Inicialmente poderá ocorrer uma crise de liquidez, quando a empresa não conseguirá transformar, no tempo requerido, os seus ativos em moeda para pagar seus compromissos. No momento seguinte poderá ocorrer a falência, situação em que os ativos da firma são menores que seus passivos.

CAOQUETTE, ALTMAN e NARAYANAM (1999), igualmente, enfatizam a importância do fluxo de caixa na definição da liquidez das empresas, principalmente o fluxo de caixa operacional que mostra se as empresas são capazes de gerar recursos suficientes a partir de suas operações principais e acrescentam que, de modo geral, os índices de lucratividade, liquidez e endividamento, parecem ser os mais apropriados na construção dos modelos de previsão de insolvência ancorados em dados contábeis. A ordem da importância de cada um dos índices não é clara e, então as questões-chaves são:

- a) Que índices são mais relevantes para a detecção da potencial insolvência?;
- b) Que pesos devem ser atribuídos aos índices selecionados?;

c) Como podemos estabelecer objetivamente o tamanho dos pesos?

DAMODARAN (1997) avalia que uma empresa em dificuldades financeiras tem as seguintes características:

a) Incapacidade de gerar fluxos de caixa suficientes para atender aos pagamentos de credores (juros e principal de dívidas) e acionistas (dividendos);

b) Alto coeficiente de endividamento em relação ao Patrimônio Líquido.

MATOS (2003) relata que ROSS (1977), em seu estudo sobre decisões de estrutura de capital com informação assimétrica, apresentou a idéia de se utilizar o endividamento como sinalizador da qualidade dos gestores da empresa. Consideradas as premissas de que os gerentes têm mais informações sobre a empresa que os agentes externos, os retornos são representados por variáveis aleatórias com distribuição normal no intervalo $[0,k]$ e que as firmas são classificadas por seu tipo, K , definido no espaço $[c,d]$, ROSS sugeriu que a remuneração do gerente fosse composta de duas partes como segue:

$$M_0 = \gamma_0(1+r)V_0$$

$$M_1 = \gamma_1 E(X - L1_{(x < B)}),$$

Sendo:

γ_0 = número real

r = taxa de retorno ajustada ao risco da firma

γ_1 = número real

V_0 = Valor de mercado da firma

X = expectativa de retorno da firma

L = penalidade em caso de insolvência

A primeira equação diz que uma parte, M_0 , da remuneração do gerente depende do valor de mercado da firma e a segunda equação sugere que a outra parte, M_1 , será proporcional ao retorno da empresa menos uma penalidade em caso de insolvência. O proprietário do capital avalia que quanto maior o montante de dívida maior o risco de insolvência e então o gerente terá que ser cada vez mais eficiente para maximizar sua remuneração. Para definir o valor ótimo da dívida Ross deduziu a equação:

$$B = \frac{\gamma_0}{4\gamma_1 L} [t^2 - c^2]$$

Onde:

B = dívida emitida.

γ_0 e γ_1 = números reais

L = penalidade em caso de bancarrota

t = tipo de firma conhecido com certeza

c = tipo de firma inserido no intervalo $[c,d]$

Embora o escopo principal do estudo tenha sido a relação entre estrutura ótima de capital e a remuneração ideal do gerente da firma, ele sugere também que a captação de recursos de terceiros incrementa o risco de bancarrota.

HARRIS e RAVIV (1991) demonstraram formalmente o modelo de ROSS (1977) e concluíram baseados em resultado empírico, que o nível de endividamento, o valor da empresa e a probabilidade de insolvência têm correlação positiva.

Os resultados dos estudos aqui apresentados permitem inferir que a decisão sobre alocação de recursos tem importante função na criação de valor e no nível da capacidade de pagamento. A estrutura de capital, financiamento ou endividamento tem implicações sobre o custo de capital, resultados e, também, sobre capacidade de pagamento. Através dos resultados – lucros ou prejuízos - podemos medir a rentabilidade auferida e os fluxos de caixa necessários para suprir os compromissos com terceiros, investimentos e remuneração dos acionistas. Então, a escolha das variáveis do presente estudo será baseada nestes resultados e, utilizando as técnicas estatísticas apropriadas, serão determinadas aquelas com maior poder de explicação sobre o evento a ser modelado.

As variáveis utilizadas neste estudo foram segregadas conforme suas referências com as decisões financeiras ou subgrupos contábeis como apresentadas a seguir:

3.4.1 Variáveis relacionadas à Estrutura de Ativos

A decisão sobre alocação de recursos tem importante reflexos sobre a geração de caixa da firma. Os ativos devem atender, principalmente, o equilíbrio da relação risco e retorno, mas devem também proporcionar ao gestor boa capacidade de liquidez. Os indicadores a seguir evidenciam a escolha da firma com relação a decisão de alocação do total dos recursos captados.

$$i) \textit{EstA} = \frac{\text{Capital de giro Líquido}}{\text{Ativo Total}}, \text{ Capital de Giro Líquido em relação ao Ativo}$$

Total. Variável representativa da composição dos ativos.

O capital de giro líquido é definido pela diferença entre os ativos com maior liquidez (ativos circulantes) e as dívidas de curto prazo (passivo circulante). Quanto

maior o resultado desta diferença, melhor será a capacidade de pagamento. Vale lembrar que, assim como o montante de recursos alocados em ativos de curto prazo, a qualidade destes bens e direitos é fundamental, pois a ocorrência de perdas implicará comprometimento da capacidade de pagamento de curto prazo.

ii) $AGRen = (\text{Ativo Total} - \text{Ativos não geradores de Renda})$, Ativos geradores de renda em relação ao ativo total. Variável que evidencia o montante de recursos alocados em ativos que tem relação direta com a geração de receitas da empresa. Quanto mais recursos forem direcionados para ativos geradores de renda melhor a capacidade de geração de caixa.

iii) $ACir = \text{Tamanho do Ativo Circulante}$. Variável indicativa da capacidade de pagamento de curto prazo.

3.4.2 Variáveis relacionadas à Estrutura de Capital ou de Financiamento

A composição das fontes de financiamento ou estrutura de capital é de extrema importância para os resultados e continuidade da companhia. Quanto maior o montante de recursos captados junto a terceiros, maior o risco de bancarrota e, sendo assim o gerente é pressionado a ser cada vez mais eficiente na busca pela obtenção de fluxos de caixa suficientes para garantir o pagamento dos compromissos financeiros e a remuneração dos acionistas. Os índices a seguir evidenciam a escolha da firma com relação a decisão de captação dos recursos e o risco associado a esta decisão.

$$\text{iv) } EstC = \frac{\text{Passivo Circulante} + \text{Exigível a Longo Prazo}}{\text{Patrimônio Líquido}} .$$

Variável derivada da estrutura de capital. Mostra a proporção entre o montante de recursos de terceiros (soma do passivo circulante mais o exigível a longo prazo) em relação aos recursos próprios (Patrimônio Líquido). Considerando que os recursos próprios investidos na firma são, em última instância, a garantia para liquidação dos compromissos com terceiros, quanto maior o resultado da relação acima, maior o risco do negócio.

$$v) \text{ MCPd} = (PL - \text{Ativos de baixa Liquidez}) .$$

Montante dos recursos próprios disponíveis. Variável que procura evidenciar o montante do capital próprio disponível. Computada pela diferença entre o montante de recursos próprios e os valores alocados em ativos de baixa liquidez tais como despesas pagas antecipadamente, impostos à recuperar, ativo diferido, incentivos fiscais e empréstimos compulsórios. O montante de recursos próprios tem importante função de sinalização quanto capacidade de absorver perdas e sendo assim quanto menor o comprometimento do capital próprio com ativos de baixa liquidez melhor a garantia dos compromissos com terceiros.

$$vi) \text{ AFRLP} = \text{Ativo Total} - \text{Passivo Circulante} .$$

Ativos financiados com recursos de longo prazo. Quanto maior o volume de ativos financiados com obrigações de longo prazo, melhor a capacidade de pagamento de curto prazo.

3.4.3. Variáveis relacionadas à geração de caixa ou Retornos

A capacidade de geração de caixa é um indicativo do valor firma e da qualidade das decisões sobre captação e aplicação dos recursos. As empresas com

boa capacidade de geração de caixa são, em geral, mais sólidas. As variáveis a seguir mostram o nível de geração de caixa e de retorno.

$$\text{vii) } EBITCT = \frac{EBIT}{PC + ELP}.$$

Variável que mede a proporção do fluxo de caixa da empresa (Resultado operacional - Resultado Financeiro + Depreciação e Amortização – Resultado da Equivalência Patrimonial) em relação a suas despesas financeiras. O EBIT, Earnings Before Interest and Tax, é uma medida do fluxo de caixa operacional das firmas. Quanto maior o resultado deste quociente, menor a probabilidade da empresa apresentar dificuldade na liquidação de seus compromissos financeiros.

$$\text{viii) } ReCP = \frac{\text{Lucro Líquido}}{\text{Patrimônio Líquido/índice de inflação}}.$$

Retorno do capital próprio - demonstra quão eficiente foi a gestão dos recursos próprios investidos no negócio. O retorno do capital próprio depende da eficiência operacional (margem de lucro), da gestão dos ativos (giro dos ativos) e da alavancagem financeira.

$$\text{ix) } RORL = \frac{\text{Lucro operacional} - \text{Despesas Financeiras}}{\text{Receitas Líquidas}}.$$

Variável representativa da eficiência operacional. Procura evidenciar qual o retorno dos ativos após o pagamento dos custos fixos e variáveis e dos encargos incidentes sobre os recursos de terceiros. As empresas que conseguem alocar os recursos de terceiros em ativos com rentabilidades superiores aos custos destas fontes, auferem maiores retornos operacionais.

$$\text{x) } ROACir = \frac{\text{Receita Operacional Líquida}}{\text{Ativo Circulante}}.$$

Variável que evidencia a proporção entre vendas e ativos de curto prazo. Em geral, variações nas vendas refletem no volume de recursos aplicados no ativo circulante que por sua vez precisam de fontes adequadas de financiamento.

3.4.4 Variáveis relacionadas à Liquidez

A capacidade de cumprir obrigações financeiras, principalmente as de curto prazo, é fundamental para a continuidade da empresa. A decisão sobre a alocação de recursos determina também o nível de liquidez da firma. As variáveis a seguir mostram o nível de liquidez das firmas.

$$xi) Liq = \frac{\text{Ativo Circulante}}{\text{Ativo Total}} - \frac{\text{Passivo Circulante}}{\text{Passivo Total}} .$$

Medida de liquidez das empresas. Quanto maior a proporção de recursos alocados em ativos de curto prazo comparados com as exigibilidades de curto prazo, melhor será a capacidade de pagamento da firma.

3.4.5 Variáveis relacionadas à eficiência operacional

A eficiência operacional das empresas depende significativamente das decisões sobre captação e alocação de recursos e também da performance do gerente no que diz respeito aos custos de produção. A eficiência operacional contribui para aumentar a geração de caixa e a criação de valor. Os indicadores a seguir são utilizados como medida para medir a eficiência das firmas.

$$xii) EVARL = \frac{\text{EVA}}{\text{Receita Líquida}} .$$

Variável que mostra quanto valor é adicionado a riqueza do acionista em relação a suas vendas. O EVA, Economic Value Added ou Valor Econômico Agregado, é fundamentado no pressuposto econômico de que as empresas, para serem viáveis, devem gerar mais riqueza que o custo de capital que empregam. Um aumento sustentado no EVA resultará em um aumento no valor de mercado de uma companhia.

3.5. Transformações de Variáveis

O ponto de partida para o entendimento da natureza de qualquer variável é o estudo das suas características. Algumas medidas estatísticas podem ser utilizadas para verificar qual o tipo de distribuição, a relação entre as variáveis. É importante, também examinar se as diferenças entre os grupos são suficientes para suportar a significância estatística.

A verificação de ocorrência de valores extremos também é importante assim como a verificação da distribuição de probabilidade das variáveis independentes. HAIR et al (2005) sugere alguns procedimentos para correção de problemas de normalidade, homocedasticidade e linearidade. Para corrigir problemas de normalidade a transformação mais usual é a inversa ($1/Y$ ou $1/X$). As distribuições assimétricas podem ser corrigidas computando-se a raiz quadrada, logaritmos ou mesmo o inverso da variável. Para se conseguir linearidade podem ser usadas as transformações raiz quadrada, quadrado, logaritmo ou o inverso da variável.

De acordo com os procedimentos sugeridos por HAIR et al algumas transformações foram aplicadas às variáveis conforme quadro a seguir.

Variável original	Nova variável
AGRen = (Ativo Total – Ativos não Geradores de Renda)	LogAGRen = Logaritmo (Ativo Total – Ativos não Geradores de Renda)
ACir = Ativo Circulante	LogACir = logaritmo (Ativo Circulante)
EstC = (Passivo Circulante + Exigível a longo Prazo) / (Passivo Total)	EstC = (Passivo Circulante + Exigível a longo Prazo) / (Passivo Total) ²
MCPd = (Patrimônio Líquido – ativos de baixa liquidez)	RCMCPd = (Patrimônio Líquido – ativos de baixa liquidez) ^(1/3)
AFRLP = (Ativo Total – Passivo Circulante)	LogAFRLP = logaritmo (Ativo Total – Passivo Circulante)
ROACir = (Receita Operacional / Ativo Circulante)	QROACir = (Receita Operacional / Ativo Circulante) ²

3.6. Análise exploratória de dados

Em seguida às transformações, são gerados gráficos do tipo boxplot para exame das características das possíveis variáveis preditoras. Este procedimento, denominado análise exploratória dos dados, é recomendável para que o uso das ferramentas estatísticas tenha resultados satisfatórios.

Os gráficos têm um grande poder de mostrar padrões de dados sob estudo e o boxplot, do tipo histograma, fornece informações sobre estes padrões, mostrando as seguintes características do conjunto de dados: dispersão, assimetria e valores discrepantes (outliers). O limite superior e o limite inferior da caixa (box) delimitam os quartis superior (3º.) e inferior (1º.) da distribuição de dados. O posicionamento da mediana, indicado por um asterisco (*), mostra se há assimetria. Se ela, a

mediana, se encontra próxima a um dos extremos é indício de assimetria naquela direção. Quanto maior a distância entre os extremos, maior a dispersão das observações.

3.7. Nível de significância

Antes da aplicação de testes estatísticos devemos estabelecer o nível ou probabilidade de significância, normalmente denominado α . Ele representa uma medida ou grau de certeza a partir do qual assumimos como real o resultado da estatística obtido no estudo ou, em outras palavras, a probabilidade de que uma prova estatística apresente um valor (p-valor) que conduza a rejeição da hipótese nula, H_0 , quando esta é verdadeira. A regra geral é rejeitar H_0 se o p-valor $\leq \alpha$. Segundo BUSSAB (2003), Fisher (1954) sugeriu a tabela, a seguir, com uma escala do nível de significância.

p-valor	0,100 (10%)	0,050 (5%)	0,025 (2,5%)	0,010 (1%)	0,005 (0,5%)	0,001 (0,1%)
evidência contra H_0	marginal	moderada	substancial	forte	muito forte	fortíssima

A escala mostra que quanto menor o p-valor mais forte será a evidência contra H_0 .

Outros parâmetros como controle das variáveis, confiabilidade dos dados, características das variáveis da amostra e a fidedignidade dos instrumentos de medidas também devem ser levados em consideração na escolha do nível de significância.

Para este estudo foi definido o nível de significância de 5,0%.

3.8. Teste de normalidade

Para verificar o tipo de distribuição das variáveis independentes será utilizado o teste de Kolmogorov-Smirnov (K-S) sugerido por MAROCO (2003). O teste é usado para determinar se uma variável sob estudo ($F(X)$) tem distribuição normal, com parâmetros μ (média) e σ (variância) quaisquer. As hipóteses a serem testadas são:

$H_0 : X \sim N(\mu; \sigma)$, a variável tem distribuição normal com média μ e variância σ .

$H_1 : X \neq N(\mu; \sigma)$, a variável não tem distribuição normal.

Para computar a estatística do teste é preciso determinar a diferença entre a frequência acumulada de cada uma das observações e a frequência acumulada que esta observação teria se a sua distribuição de probabilidade fosse normal e a diferença relativa a observação anterior. A estatística do teste é dada, então, pela maior diferença destas duas diferenças de modo que:

$$D = \max \left\{ \max (|F(x_i) - F_0(x_i)|), \left\{ \max (|F(x_{i-1}) - F_0(x_i)|) \right\}; \text{ com } F_0 X \sim N(\mu; \sigma) \right.$$

Rejeita-se H_0 se $D \geq D_{\text{tabelado}}(\alpha)$. O SPSS calcula o *p*-valor (α) a partir do qual $D \geq D_{\text{tabelado}}(\alpha)$, utilizando uma aproximação analítica da estatística de teste de Lilliefors proposta por Dallal & Wilkinson (1986). Este procedimento é necessário para corrigir possíveis problemas da distribuição K-S quando comparamos a distribuição de frequências acumuladas das observações da variável com uma distribuição teórica cujos parâmetros foram estimados a partir da amostra. Assim para uma determinada probabilidade de erro do tipo I rejeita-se H_0 se *p*-valor $\leq \alpha$.

Outra medida usada para avaliar o tipo de distribuição das observações é o teste de Shapiro-Wilk. Este teste é preferível ao teste Kolmogorov-Smirnov no caso

de amostras de pequena dimensão (menos de 30 observações). A Estatística do teste é:

$$W = \frac{\left(\sum_{i=1}^n a_i x_i\right)^2}{\sum_{i=1}^n (x_i - \bar{x})^2},$$

Onde:

x_i = Valores da variável X, ordenados em ordem crescente

\bar{x} = Média de X

a_i = Constantes geradas a partir da média, variância e covariância das n variáveis com distribuição N (0,1).

Valores pequenos de W indicam que a distribuição da variável sob estudo é do tipo normal. O SPSS produz o p-value para este teste sempre que a dimensão da amostra seja menor ou igual a 50.

3.9. Teste de Homogeneidade das variâncias

Homocedasticidade é a variância constante dos resíduos. Esta é uma propriedade fundamental para a análise discriminante e deve ser garantida, sob pena de invalidar toda a análise estatística. Deseja-se que os erros sejam aleatórios, ou seja, não devem ser relacionados com as características das variáveis. Se isto não ocorre, há heterocedasticidade, o que significa dizer que as chances de ocorrerem erros grandes (ou pequenos) variam conforme o valor da variável, em outras palavras, há tendências nos erros. As conseqüências da heterocedasticidade são que as estimativas dos parâmetros da regressão não são tendenciosas mas são

ineficientes e as estimativas das variâncias são tendenciosas. Os testes t e F tendem a dar resultados incorretos. Neste caso, os resultados não são confiáveis, ou seja, o modelo pode parecer bom, mas ele não é adequado aos dados, na verdade.

O teste de Levene, sugerido por MAROCO (2003), é usado para testar se as variâncias populacionais computadas a partir de k amostras são homogêneas (iguais).

A estatística do teste é dada por:

$$W = \frac{N - k}{k - 1} \cdot \frac{\sum_{i=1}^k N_i \cdot (Z_i - Z)^2}{\sum_{i=1}^k \sum_{j=1}^{N_i} (Z_{ij} - Z_i)^2}$$

Onde:

- Z_i - é a média dos Z_{ij} na categoria i.
- Z - média total de todos os Z_{ij} .
- N - tamanho total das amostras.
- N_i - tamanho da amostra da i-ésima categoria.
- k - número de categorias.
- Z_{ij} - medida de dispersão.

A medida de dispersão é definida pela seguinte expressão:

$$Z_{ij} = | Y_{ij} - Y_i |$$

Onde Y_i pode ser a média da i-ésima categoria ou a mediana da i-ésima categoria.

As hipóteses do teste são:

$$H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_k^2 \quad \text{versus} \quad H_1 : \exists i, j; \sigma_i^2 \neq \sigma_j^2$$

Sob H_0 , $W \sim F(k-1, N-k)$. Significa dizer que, para uma determinada probabilidade de erro (α) rejeita-se H_0 se $W \geq f_{1-\alpha};(k-1, N-k)$, sendo que a probabilidade de significância, p-valor, é o menor valor, a partir do qual $W \geq f_{1-\alpha};(k-1, N-k)$ e este valor é calculado pela maioria dos programas estatísticos, em particular o SPSS usado neste estudo.

3.10. Teste de Homogeneidade das matrizes de variância-covariância

O pressuposto de que a matriz de variância-covariância para cada um dos grupos em estudo em relação a cada uma das p-variáveis provenham de uma mesma população de variância-covariância, de modo que uma estimativa conjunta da variância residual possa ser obtida, não pode ser violada sob pena de comprometimento da robustez da função discriminante. O teste mais utilizado para avaliar a hipótese de homogeneidade das matrizes de variância-covariância é o M de Box. As hipóteses do teste são:

$$H_0 : \Sigma_1 = \Sigma_2 = \dots = \Sigma_m$$

$$H_1 : \exists i, j : \Sigma_i \neq \Sigma_j \text{ com } i \neq j; i, j = \{1, \dots, m\}$$

A estatística do teste é dada por:

$$M = (N - m) \log|S| - \sum_{i=1}^m (n_j - 1) \log|S_i|, \text{ sendo:}$$

$|S| > 0$ para uma matriz S de variância-covariância positiva e definida,

onde:

$$N = n_1 + n_2 + \dots + n_m \quad \text{e}$$

$$S = \frac{\sum_{i=1}^m (n_i - 1) S_i}{N - m}, \quad \text{com } S_i \text{ sendo a matriz de variância-covariância do grupo } i \text{ (para } N > m \text{)}.$$

Se a dimensão de todas as amostras for igual, a função discriminante pode ser considerada robusta relativamente à não violação do pressuposto de homogeneidade das matrizes de variância-covariância.

3.11. Seleção das variáveis discriminantes

A seleção das variáveis discriminantes (m), dado um conjunto de p - variáveis é o passo inicial para estimação da função discriminante.

MAROCO (2003) diz que de acordo com a teoria da decisão é através do teste de hipótese que podemos refutar ou não determinada hipótese sobre uma ou mais variáveis inseridas em uma amostra. Para decidirmos se uma determinada variável é significativa, devemos testar a igualdade de suas médias nos grupos em estudo através das hipóteses:

$H_0 : \mu_{1i} = \mu_{2i} = \dots = \mu_{ki}$ a variável apresenta média semelhante nos grupos, ou seja, não é discriminante.

$H_1 : \exists \mu_{1i} \neq \mu_{ki}$ as médias da variável em estudo são diferentes.

O SPSS apresenta o p-valor - o menor nível de significância (α) a partir do qual a hipótese nula, H_0 , pode ser rejeitada - associado a estatística F. Se p-valor >

α devemos aceitar H_0 , caso contrário devemos rejeitar esta hipótese em favor da hipótese alternativa, concluindo que a variável é significativa, discrimina os grupos, pois $p\text{-valor} \leq \alpha$.

3.12. Estimação da Função Discriminante

Dois métodos computacionais podem ser utilizados para determinar uma função discriminante: o método simultâneo ou direto e o método stepwise ou passo a passo.

Na estimação simultânea a função discriminante é computada de modo que todas as variáveis independentes são consideradas conjuntamente sem considerar o poder discriminatório de cada uma delas. Assim a função discriminante é computada com base no conjunto inteiro de variáveis independentes, sem consideração do poder discriminatório de cada uma destas variáveis.

No método passo a passo as variáveis são escolhidas conforme seu poder discriminatório. Primeiramente é escolhida aquela variável que melhor discrimina os grupos, utilizando para isto, geralmente, F -test. Em seguida ela é combinada com cada uma das outras variáveis para que seja selecionado o par de variáveis que melhora o poder discriminatório. O passo seguinte é combinar este par com as variáveis restantes de modo que seja encontrada outra variável que melhore ainda mais o poder discriminatório. Este procedimento é repetido até que seja encontrado o melhor conjunto de variáveis para compor a função discriminante. O método permite, no caso de um grande número de variáveis em estudo, a eliminação daquelas que não são úteis na discriminação dos grupos.

MAROCO (2003) sugere a utilização das estatísticas Distância de Mahalanobis, V de Rao e Razão F entre grupos para corroborar ou não a escolha efetuada com o uso do critério lambda de Wilks e para diagnosticar possíveis problemas de multicolinearidade, o que implicaria na existência de viés no modelo, o autor indica a medida tolerância.

A Distância de Mahalanobis, DM_{ij} , entre variáveis i e j é dada por:

$$DM_{ij} = \sqrt{((X_i - X_j)' S^{-1} (X_i - X_j))},$$

onde:

X_i e X_j = são variáveis dos grupos i e j

S^{-1} = Matriz de covariância

O quadrado desta distância é utilizado para demonstrar quanto um grupo se diferencia de outro. Assim, uma variável é adicionada a função discriminante se a sua inclusão aumentar significativamente a DM^2 . Esta estatística é sugerida quando as variáveis sob estudo apresentam correlações significativas que podem causar desvio no resultado da função discriminante.

O critério V de Rao objetiva maximizar a distância entre os centróides dos grupos para tanto é computado o valor do centróide geral pela fórmula:

$$V = - (n - g) \sum_{i=1}^p \sum_{j=1}^p w_{ij}^{-1} (t_{ij} - w_{ij}),$$

onde:

n = dimensão da amostra

g = número de grupos

w_{ij} e t_{ij} = elementos genéricos das matrizes W e T , respectivamente.

A significância da variação do V de Rao, derivada da adição ou remoção de uma variável, pode ser avaliada por aproximação à distribuição qui-quadrado com $g - 1$ graus de liberdade.

A razão F entre grupos é uma transformação da distância de Mahalanobis, considerando as diferentes dimensões entre os grupos, de maneira que os grupos de maior dimensão tenham maior peso na análise.

Dado dois grupos a e b a razão F , F_{ab} , é computada como:

$$F_{ab} = \frac{(n - p - g)n_a n_b}{p(n - p)(n_a + n_b)} DM_{ab}^2,$$

onde:

n = dimensão da amostra

g = número de grupos

p = número de variáveis

DM_{ab}^2 = Distância de Mahalanobis entre os grupos a e b

A medida de tolerância de uma variável X_i é definida como $T = 1 - R_i^2$, onde R_i^2 é o coeficiente de determinação do modelo composto da variável dependente, X_i , e as variáveis independentes, X_j . Quanto mais próximo de 0 (zero) é o valor da medida de tolerância, maior é o problema de correlação entre variáveis e mais instável será o modelo. Por outro lado, quanto mais próximo de 1 (um) mais estável será o modelo.

3.13. Determinação do ponto de corte

O ponto de corte, também conhecido como valor crítico, é o critério base para decisão sobre a classificação dos indivíduos em cada um dos grupos previamente definidos. Ele é calculado como segue:

$$f = \frac{n_0 \bar{d}_0 + n_1 \bar{d}_1}{n_0 + n_1}, \text{ onde:}$$

\bar{d}_1 e \bar{d}_2 = centróides (médias) dos grupos e n_0 e n_1 = dimensões - números de indivíduos dos grupos.

Então, o individuo será classificado do grupo 0 se o escore computado na função discriminante (z) for menor que o ponto de corte, $z < f$ e no caso de $z > f$ o individuo será classificado no grupo 1.

A área entre estes dois valores corresponde a zona de indefinição, onde não é possível classificar o individuo em dos dois grupos.

4. Análise dos Resultados

4.1. Dispersão, assimetria e discrepância.

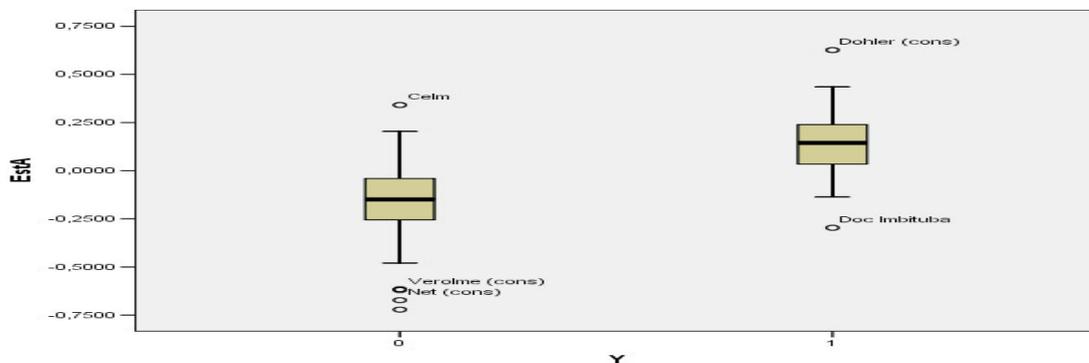


Figura 1: Box Plot da variável EstA para os grupos 0 (empresas insolventes) e 1 (empresas solventes).

A variável EstA, conforme figura 1, apresentou valores extremos (outliers) nos grupos. A posição da mediana sugere pequena assimetria na distribuição dos dados e pouca diferenciação entre os grupos. A distância entre os extremos indica pouca dispersão.

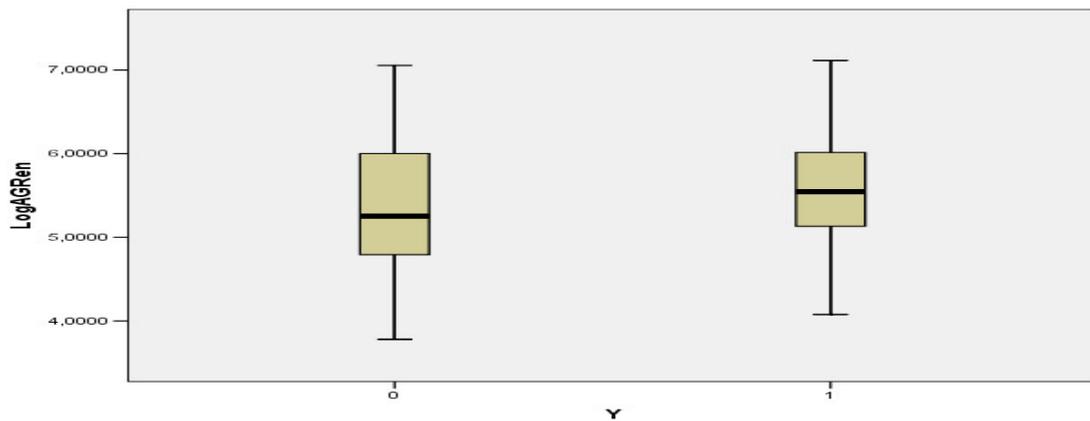


Figura 2: Box Plot da variável LogAGRen para os grupos 0 (empresas insolventes) e 1 (empresas solventes).

A variável LogAGRen, conforme figura 2, não apresentou valores extremos (outliers) nos dois grupos. A posição da mediana sugere que a distribuição dos dados é mais assimétrica no grupo das empresas insolventes, assim como a dispersão. Ainda com base na posição da mediana podemos inferir que existe pouca diferenciação entre estes grupos.

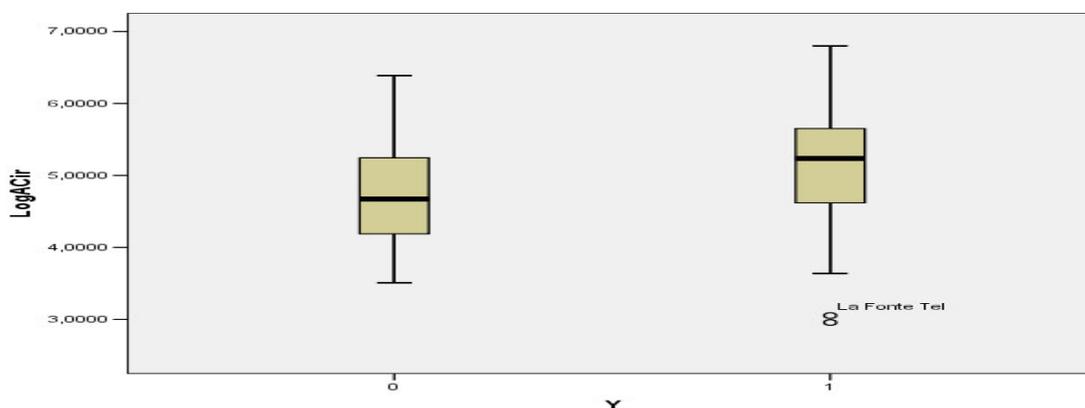


Figura 3: Box Plot da variável LogACir para os grupos 0 (empresas insolventes) e 1 (empresas solventes).

A figura 3 mostra a ausência de valores extremos (outliers) no grupo das empresas insolventes, diferentemente do grupo das empresas solventes. A assimetria e a dispersão no grupo das empresas solventes são maiores que no grupo das insolventes e a discriminação entre os grupos não é relevante.

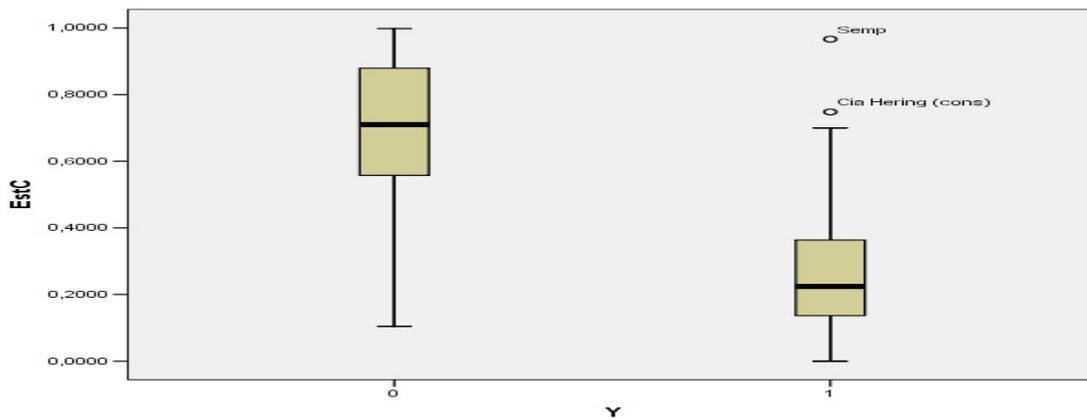


Figura 4: Box Plot da variável EstC para os grupos 0 (empresas insolventes) e 1 (empresas solventes).

A figura 4 mostra a ausência de valores extremos (outliers) no grupo das empresas insolventes, diferentemente do grupo das empresas solventes. A assimetria no grupo das empresas solventes é maior, a dispersão das observações é acentuada, nos dois grupos, e a discriminação entre os grupos é significativa.

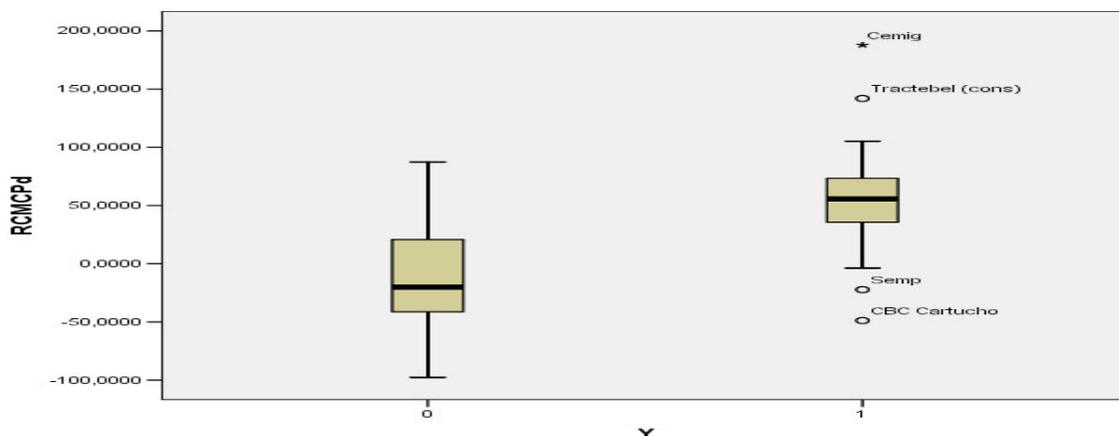


Figura 5: Box Plot da variável RCMCPd para os grupos 0 (empresas insolventes) e 1 (empresas solventes).

A figura 5 mostra a presença de valores extremos (outliers) no grupo das empresas solventes, diferentemente do grupo das empresas insolventes. A assimetria no grupo das empresas insolventes é maior, a dispersão das observações não é acentuada, nos dois grupos, e a discriminação entre os grupos é significativa.

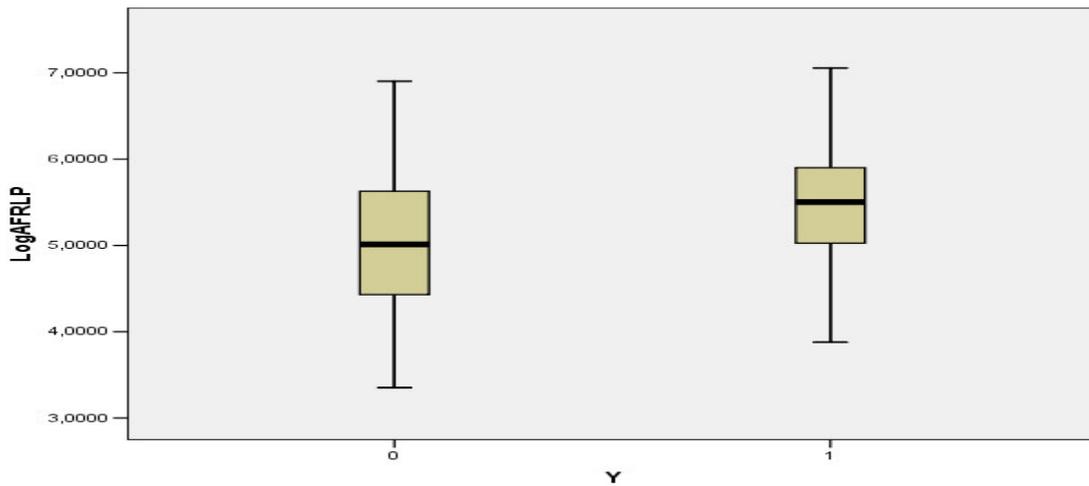


Figura 6: Box Plot da variável LogAFRLP para os grupos 0 (empresas insolventes) e 1 (empresas solventes).

A figura 6 revela a ausência de valores extremos (outliers) nos dois grupos. A assimetria no grupo das empresas solventes é maior, a dispersão das observações não é acentuada, nos dois grupos, e a discriminação entre os grupos é significativa.

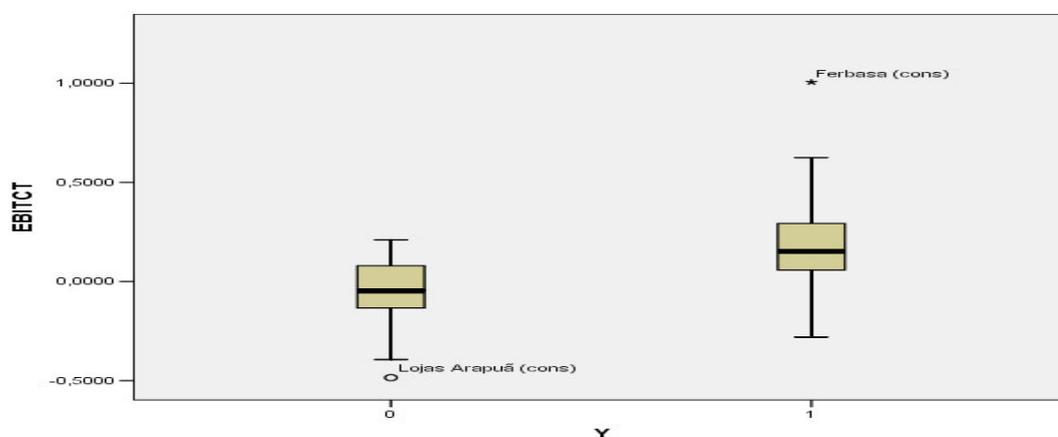


Figura 7: Box Plot da variável EBITCT para os grupos 0 (empresas insolventes) e 1 (empresas solventes).

A figura 7 mostra a presença de valores extremos (outliers) nos dois grupos. A assimetria tem nível equivalente nos dois grupos, a dispersão das observações não é acentuada, sendo menor no grupo das empresas insolventes, e a discriminação entre os grupos é significativa.

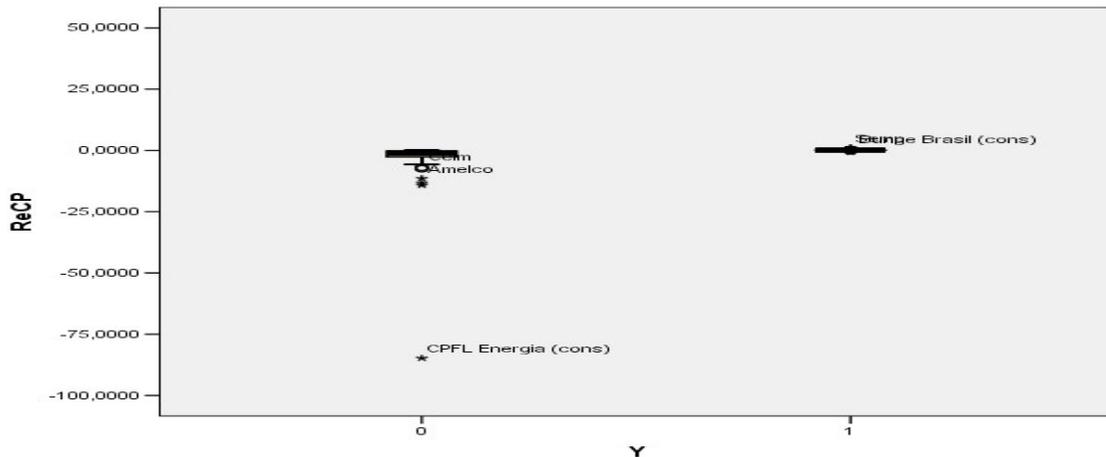


Figura 8: Box Plot da variável ReCP para os grupos 0 (empresas insolventes) e 1 (empresas solventes).

A figura 8 mostra a presença de valores extremos (outliers) nos dois grupos. A dispersão das observações não é significativa, inexistente assimetria e discriminação entre os grupos.

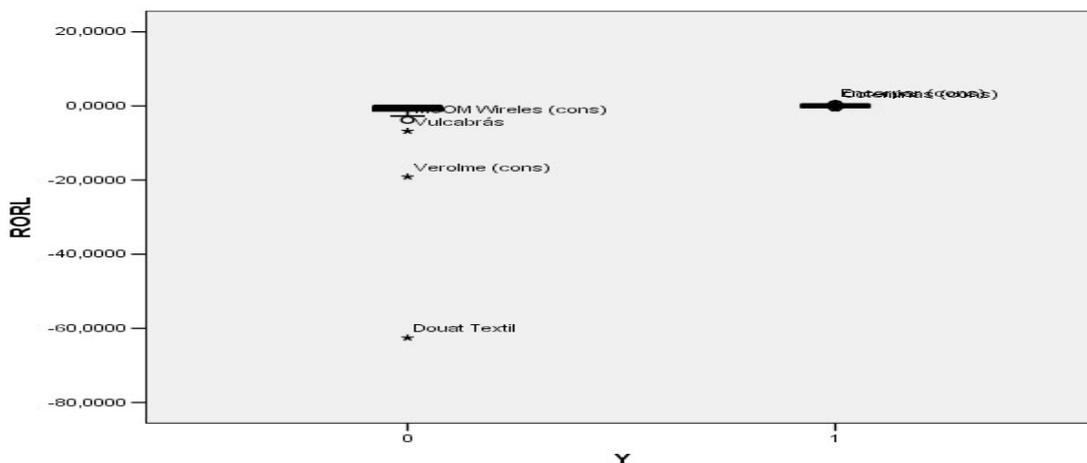


Figura 9: Box Plot da variável RORL para os grupos 0 (empresas insolventes) e 1 (empresas solventes).

A figura 11 mostra a presença de valores extremos (outliers) nos dois grupos. A dispersão, a assimetria e a discriminação não são significantes.

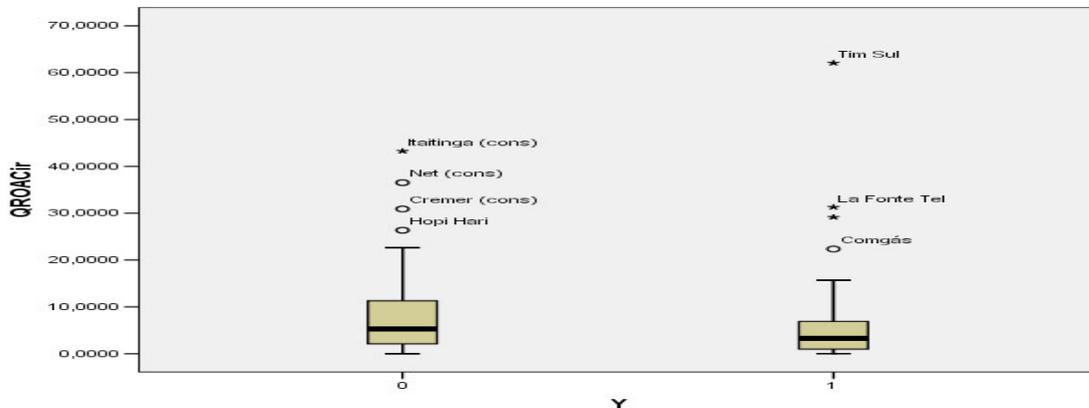


Figura 12: Box Plot da variável QROACir para os grupos 0 (empresas insolventes) e 1 (empresas solventes).

A figura 12 mostra a presença de valores extremos (outliers) nos dois grupos. A dispersão, a assimetria e a discriminação não são significantes.

Os gráficos box plot apontam algumas variáveis (LogAGRen, LogACir, RORL, EVARL e QROACir) não discriminantes e a ocorrência de observações atípicas. Estes problemas não receberam tratamento por dois motivos: Em primeiro lugar por não poder ser demonstrado o efeito sobre o resultado da pesquisa e em segundo lugar elas foram mantidas para preservar a generalidade da amostra.

4.2. Teste de Normalidade

4.2.1. Resultado para a variável EstA:

Teste de normalidade						
Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	estatística	df	Sig.	estatística	df	Sig.
EstA 0	,154	35	,034	,958	35	,194
1	,080	35	,200	,985	35	,905

a. Com correção de Lilliefors.

Com p -valor (Sig) de 0,034 e 0,200 e uma probabilidade de erro de 5% ($\alpha=0,05$) pode-se concluir que a distribuição de probabilidade da variável EstA no grupo das empresas solventes, onde $p \geq \alpha$., é normal. O resultado para o grupo das empresas insolventes mostra um pequeno desvio da normalidade com $p=0,34 < \alpha = 0,05$.

4.2.2. Resultado para a variável LogAGRen:

Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	df	Sig.	estatística	df	Sig.
LogAGRen 0	,110	35	,200 *	,965	35	,329
1	,081	35	,200 *	,984	35	,866

a. Com correção de Lilliefors

Com p -valor (Sig) de 0,200 e 0,200 e uma probabilidade de erro de 5% ($\alpha=0,05$) pode-se concluir que a distribuição de probabilidade da variável LogAGRen, nos dois grupos, é normal, $p \geq \alpha$.

4.2.3. Resultado para a variável LogACir:

Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	estatística	df	Sig.
LogACir 0	,084	35	,200 *	,970	35	,446
1	,103	35	,200 *	,970	35	,449

a. Com correção de Lilliefors.

Com p -valor (Sig) de 0,200 e 0,200 e uma probabilidade de erro de 5% ($\alpha=0,05$) pode-se concluir que a distribuição de probabilidade da variável LogACir, nos dois grupos, é normal, $p \geq \alpha$.

4.2.4. Resultado para a variável EstC:

Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	df	Sig.	estatística	df	Sig.
EstC 0	,119	35	,200 *	,951	35	,119
1	,147	35	,053	,899	35	,004

a. Com correção Lilliefors

Com *p*-valor (Sig) de 0,200 e 0,053 e uma probabilidade de erro de 5% ($\alpha=0,05$) pode-se concluir que a distribuição de probabilidade da variável EstC, nos dois grupos, é normal, $p \geq \alpha$.

4.2.5. Resultado para a variável RCMCPd:

Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	df	Sig.	estatística	df	Sig.
RCMCPd 0	,105	35	,200 *	,980	35	,758
1	,129	35	,150	,942	35	,062

a. Com correção de Lilliefors

Com *p*-valor (Sig) de 0,200 e 0,150 e uma probabilidade de erro de 5% ($\alpha=0,05$) pode-se concluir que a distribuição de probabilidade da variável RCMCPd, nos dois grupos, é normal, $p \geq \alpha$.

4.2.6. Resultado para a variável LogAFRLP:

Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	df	Sig.	estatística	df	Sig.
LogAFRLP 0	,068	35	,200*	,987	35	,947
1	,091	35	,200*	,986	35	,925

a. Com correção de Lilliefors

Com *p*-valor (Sig) de 0,200 e 0,200 e uma probabilidade de erro de 5% ($\alpha=0,05$) pode-se concluir que a distribuição de probabilidade da variável LogAFRLP, nos dois grupos, é normal, $p \geq \alpha$.

4.2.7. Resultado para a variável EBITCT:

Teste de normalidade

Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	df	Sig.	estatística	df	Sig.
EBITCT 0	,095	35	,200 *	,960	35	,229
1	,125	35	,181	,924	35	,018

a. Com correção de Lilliefors

Com p -valor (Sig) de 0,200 e 0,181 e uma probabilidade de erro de 5% ($\alpha = 0,05$) pode-se concluir que a distribuição de probabilidade da variável EBITCT, nos dois grupos, é normal, $p \geq \alpha$.

4.2.8. Resultado para a variável ReCp:

Teste de normalidade

Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	df	Sig.	estatística	df	Sig.
ReCP 0	,363	35	,000	,336	35	,000
1	,267	35	,000	,727	35	,000

a. Com correção de Lilliefors

Com p -valor (Sig) de 0,000 e 0,000 e uma probabilidade de erro de 5% ($\alpha = 0,05$) pode-se concluir que a distribuição de probabilidade da variável ReCP, nos dois grupos, não é normal, $p \leq \alpha$.

4.2.9. Resultado para a variável RORL:

Teste de Normalidade

Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	df	Sig.	estatística	df	Sig.
RORL 0	,403	35	,000	,328	35	,000
1	,207	35	,001	,932	35	,032

a. Com correção de Lilliefors

Com p -valor (Sig) de 0,000 e 0,001 e uma probabilidade de erro de 5% ($\alpha = 0,05$) pode-se concluir que a distribuição de probabilidade da variável RORL, nos dois grupos, não é normal, $p \leq \alpha$.

4.2.10. Resultado para a variável Liq:

Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	df	Sig.	estatística	df	Sig.
Liq 0	,123	35	,200 *	,963	35	,280
Liq 1	,073	35	,200 *	,989	35	,978

a. Com correção de Lilliefors

Com p -valor (Sig) de 0,200 e 0,200 e uma probabilidade de erro de 5% ($\alpha = 0,05$) pode-se concluir que a distribuição de probabilidade da variável Liq, nos dois grupos, é normal, $p \geq \alpha$.

4.2.11. Resultado para a variável EVARL:

Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	df	Sig.	Statistic	df	Sig.
EVARL 0	,333	35	,000	,436	35	,000
EVARL 1	,385	35	,000	,356	35	,000

a. Lilliefors Significance Correction

Com p -valor (Sig) de 0,000 e 0,000 e uma probabilidade de erro de 5% ($\alpha = 0,05$) pode-se concluir que a distribuição de probabilidade da variável EVARL, nos dois grupos, não é normal, $p \leq \alpha$.

4.2.12. Resultado para a variável QROACir:

Teste de Normalidade						
Y	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estatística	df	Sig.	Statistic	df	Sig.
QROACir 0	,197	35	,001	,787	35	,000
1	,300	35	,000	,604	35	,000

a. Lilliefors Significance Correction

Com p -valor (Sig) de 0,001 e 0,000 e uma probabilidade de erro de 5% ($\alpha = ,05$) pode-se concluir que a distribuição de probabilidade da variável QROACir, nos dois grupos, não é normal, $p \leq \alpha$.

4.3. Teste de Homogeneidade

Teste de Homogeneidade das Variâncias					
Variáveis	Parametros	Estatística Levene	df_1	df_2	Sig.
EstA	Média	2,319	1	68	0,132
	Médiana	2,046	1	60,516	0,157
	Mediana ajustada	2,046	1	68	0,158
LogAGRen	Média	0,441	1	68	0,509
	Médiana	0,426	1	67,456	0,516
	Mediana ajustada	0,426	1	68	0,516
LogACir	Média	0,561	1	68	0,457
	Médiana	0,375	1	63,309	0,542
	Mediana ajustada	0,375	1	68	0,542
EstC	Média	0,001	1	68	0,981
	Médiana	0,000	1	66,002	0,997
	Mediana ajustada	0,000	1	68	0,997
RCMCPd	Média	0,642	1	68	0,426
	Médiana	0,482	1	66,166	0,490
	Mediana ajustada	0,482	1	68	0,490
LogAFRLP	Média	1,332	1	68	0,252
	Médiana	1,330	1	67,580	0,253
	Mediana ajustada	1,330	1	68	0,253
EBITCT	Média	1,982	1	68	0,164
	Médiana	1,561	1	55,045	0,216
	Mediana ajustada	1,561	1	68	0,217
ReCP	Média	7,917	1	68	0,006
	Médiana	3,449	1	34,020	0,68
	Mediana ajustada	3,449	1	68	0,720
RORL	Média	6,803	1	68	0,011
	Médiana	2,274	1	34,030	0,136
	Mediana ajustada	2,274	1	68	0,141
Liq	Média	2,144	1	68	0,148
	Médiana	1,853	1	61,981	0,178
	Mediana ajustada	1,853	1	68	0,178
EVARL	Média	3,128	1	68	0,081
	Médiana	1,372	1	51,538	0,245
	Mediana ajustada	1,372	1	68	0,247
QROACir	Média	0,031	1	68	0,862
	Médiana	0,108	1	64,621	0,743
	Mediana ajustada	0,108	1	68	0,743

Os resultados mostram que a hipótese de homogeneidade das variâncias não pode ser rejeitada, tendo em vista que todas as variáveis, com exceção de RORL, apresentaram $p\text{-valor} > \alpha = 0,05$.

4.4. Seleção das variáveis discriminantes

Teste de igualdade das médias dos grupos					
Variáveis	Lambda de Wilk	Estatística F	df_1	df_2	Sig.
EstA	0,630	40,0071450	1	68	0,000
LogAGRen	0,963	2,6070666	1	68	0,111
LogACir	0,953	3,3523506	1	68	0,071
EstC	0,525	61,5461300	1	68	0,000
RCMCPd	0,593	46,7486100	1	68	0,000
LogAFRLP	0,912	6,5900086	1	68	0,012
EBITCT	0,705	28,5128240	1	68	0,000
ReCP	0,942	4,2170499	1	68	0,044
RORL	0,957	3,0805090	1	68	0,084
Liq	0,640	38,1943900	1	68	0,000
EVARL	0,971	2,0157180	1	68	0,160
QROACir	0,994	0,3997820	1	68	0,529

Ao nível de significância de 5,00% ($\alpha = 0,05$) podemos inferir que somente as variáveis LogAGRen ($p=0,111$), LogACir ($p=0,071$), RORL ($p=0,084$), EVARL ($p=0,160$) e QROACir ($p=0,529$) não são discriminantes.

Embora as variáveis LogAGRen e LogACir não tenham apresentado bons resultados, a variável EstA, do mesmo subgrupo, correspondeu as expectativas. As variáveis RORL e QROACir, do subgrupo geração de caixa, não apresentaram resultados significantes mas EBITCT, do mesmo grupo. Então, os resultados não significantes de algumas variáveis podem ser explicados pela presença de outras variáveis, do mesmo subgrupo, que melhor explicam o problema estudado.

4.5. Matriz de correlação

Matriz de Correlação												
	EstA	LogAGRen	LogACir	EstC	RCMCPd	LogAFRLP	EBITCT	ReCP	RORL	Liq	EVARL	QROACir
EstA	1,000	-0,174	0,061	-0,246	0,104	-0,068	0,130	0,346	-0,141	0,994	-0,142	-0,346
LogAGRen	-0,174	1,000	0,926	0,220	0,344	0,971	0,166	-0,113	0,099	-0,203	0,207	-0,112
LogACir	0,061	0,926	1,000	0,221	0,369	0,885	0,191	-0,092	0,088	0,026	0,247	-0,244
EstC	-0,246	0,220	0,221	1,000	-0,265	0,158	-0,175	-0,265	-0,044	-0,240	0,129	-0,165
RCMCPd	0,104	0,344	0,369	-0,265	1,000	0,318	-0,099	0,232	0,046	0,101	0,049	-0,003
LogAFRLP	-0,068	0,971	0,885	0,158	0,318	1,000	0,168	-0,048	0,013	-0,096	0,104	-0,094
EBITCT	0,130	0,166	0,191	-0,175	-0,099	0,168	1,000	0,011	0,005	0,117	0,140	-0,077
ReCP	0,346	-0,113	-0,092	-0,265	0,232	-0,048	0,011	1,000	-0,032	0,339	0,000	0,079
RORL	-0,141	0,099	0,088	-0,044	0,046	0,013	0,005	-0,032	1,000	-0,143	0,813	0,136
Liq	0,994	-0,203	0,026	-0,240	0,101	-0,096	0,117	0,339	-0,143	1,000	-0,146	-0,333
EVARL	-0,142	0,207	0,247	0,129	0,049	0,104	0,140	0,000	0,813	-0,146	1,000	0,175
QROACir	-0,346	-0,112	-0,244	-0,165	-0,003	-0,094	-0,077	0,079	0,136	-0,333	0,175	1,000

A matriz de correlação mostra que a variável LogACir tem forte correlação com as variáveis LogAGRen e LogAFRLP. Esta situação é derivada da composição das três variáveis, todas componentes do ativo total. As variáveis Liq e EstA também apresentaram correlação significativa, assim como EVARL e RORL. As duas últimas têm em sua composição as receitas líquidas o que provavelmente determinou a correlação.

4.6. Quadro resumo dos testes realizados

Referência	Variável	Ausência de outliers	Normalidade	Homoced.	Ausência de Correlação	Sinal Esperado	Significante
Estrutura de Ativos	EstA	não	sim	sim	não	sim	sim
	LogAGRen	sim	sim	sim	não	sim	não
	LogACir	não	sim	sim	não	não	não
Estrutura de capital	EstC	não	sim	sim	sim	sim	sim
	RCMCPd	não	sim	sim	sim	sim	sim
	LogAFRLP	sim	sim	sim	não	sim	sim
Geração de caixa	EBITCT	não	sim	sim	sim	sim	sim
	ReCP	não	não	sim	sim	não	sim
	RORL	não	não	não	não	sim	não
	QROACir	não	não	sim	sim	não	não
Liquidez	Liq	não	sim	sim	não	não	sim
Eficiência	EVARL	não	não	sim	não	sim	não

O quadro resumo mostra que as variáveis que não apresentaram o sinal esperado também apresentaram problemas de significância, correlação ou normalidade. Nenhum tratamento foi dispensado para correção dos problemas,

primeiramente para que fosse mantida, sempre que possível, a generalidade do modelo e também porque as variáveis selecionadas na estimação da função discriminante pelo método passo a passo cumpriram os pressupostos da análise discriminante.

4.7. Estimação da Função Discriminante pelo método direto

Coeficientes da Função Discriminante			
Variáveis	Coeficientes	Sinal Esperado	Sinal Calculado
EstA	7,725	Positivo	Positivo
LogAGRen	0,426	Positivo	Positivo
LogACir	-1,489	Positivo	Negativo
EstC	-1,415	Negativo	Negativo
RCMCPd	0,014	Positivo	Positivo
LogAFRLP	0,912	Positivo	Positivo
EBITCT	1,710	Positivo	Positivo
ReCP	-0,032	Positivo	Negativo
RORL	-0,008	Positivo	Positivo
Liq	-4,704	Positivo	Negativo
EVARL	0,196	Positivo	Positivo
QROACir	-0,006	Positivo	Negativo
Constante	0,616		

As variáveis, LogACir, ReCP, Liq e QROACir apresentaram sinais contrários aos esperados, provavelmente pela presença de valores extremos ou da forte correlação com outras variáveis. As demais variáveis apresentaram sinais coerentes com os esperados.

A variável que apresentou o maior coeficiente foi EstA, evidenciando que a decisão sobre alocação de recursos tem relação com a probabilidade de insolvência da firma. EBITCT também teve resultado importante, sugerindo que a geração de caixa é uma variável que separa firmas com boa capacidade de pagamento das firmas que não tem boa capacidade de cumprir seus compromissos financeiros. EstC foi mais um destaque, indicando que a decisão sobre a estrutura de capital tem impacto sobre a probabilidade de *default*. A variável RCMCPd, representativa do

montante de recursos próprios disponíveis, normalmente utilizada em estudos sobre quebra de empresas financeiras, mostrou ter poder de discriminação de firmas não financeiras.

A função derivada, pelo método direto, a partir dos resultados foi:

$$Y = 0,616 + 7,725 \text{ EstA} + 0,426 \text{ LogAG} \text{ Re } n - 1,489 \text{ LogACir} - 1,415 \text{ EstC} + 0,014 \text{ RCMCPd} + 0,912 \text{ LogAFRLP} + 1,710 \text{ EBITCT} - 0,032 \text{ Re CP} - 0,008 \text{ RORL} - 4,704 \text{ Liq} + 0,196 \text{ EVARL} - 0,006 \text{ QROACir}$$

4.8. Determinação do ponto de corte

Sumário dos casos utilizados na análise			
Grupos	Percentual	casos analisados	Centroides
0	50	35	-1,493
1	50	35	1,493

Com base nos centróides encontrados e o número de casos analisados, o ponto de corte é $f = \frac{(35 \times -1,493) + (35 \times 1,493)}{35 + 35} = 0$.

4.9. Variância-Covariância entre os grupos

Teste M de Box		
Box's M		674,297
F	Approx.	7,019
	df1	78
	df2	14601,821
	Sig.	,000

O resultado do teste M de Box, $p\text{-valor} = (\text{sig.}) = 0,000 < \alpha = 0,05$ indicou a existência de heterocedasticidade, determinando a rejeição da hipótese de serem iguais as matrizes de variâncias-covariâncias entre os grupos. Este resultado indica comprometimento no modelo de previsão computado pelo método direto já que não foi cumprido um dos principais pressupostos da análise discriminante.

4.10. Matriz de Classificação

A função computada pelo método direto classificou corretamente 92,9% dos casos (94,3% do grupo 0 e 91,4% do grupo 1) conforme quadro a seguir.

Matriz de Classificação - Método Direto					
Situação	Grupos	Classificados a priori	Previstos	Classificação correta (%)	(%) Total
Original	0	35	33	94,30	92,90
	1	35	32	91,40	
Validação Cruzada	0	35	31	88,60	85,70
	1	35	29	82,90	

4.11. Estimação da Função Discriminante pelo método passo a passo

A estimação pelo método passo a passo apresentou os seguintes resultados:

Sumário dos casos utilizados na análise			
Grupos	Percentual	casos analisados	Centróides
0	50	35	-1,333
1	50	35	1,333

Coeficientes da Função Discriminante			
Variáveis	Coeficientes	Sinal Esperado	Sinal Calculado
EstA	1,6791	Positivo	Positivo
EstC	-1,8309	Negativo	Negativo
RCMCPd	0,0120	Positivo	Positivo
EBITCT	2,0812	Positivo	Positivo
Constante	0,526		

Com os quais definimos a seguinte função discriminante:

$$Y = 0,526 + 1,679EstA - 1,831 EstC + 0,012 RCMCPd + 2,082 EBICT$$

E o ponto de corte $f = \frac{(35 \times -1,333) + (35 \times 1,333)}{(35 + 35)} = 0$ e, sendo assim, o

postulante a crédito será classificado no grupo 0 (provável insolvente) se $f < 0$ e no grupo 1 (provável solvente) se $f > 0$.

Embora a variável LogAFRLP tenha apresentado nível de significância satisfatório, ela não foi incluída na função discriminante derivada pelo método passo a passo. A exclusão desta variável deve-se ao fato de que as outras variáveis do modelo tem poder explicatório suficiente sobre o problema estudado. A utilização de outros critérios estatísticos (Distância de Mahalanobis, V de Rao e Razão F) para validar a função computada pelo método passo a passo corroboraram a escolha feita pelo critério lambda de Wilks e a possibilidade de existirem de problemas derivados de multicolinearidade foi afastada com o diagnóstico efetuado através da medida de tolerância que apresentou os seguintes resultados:

Variáveis sob análise

Passo		Tolerância	F mínimo	Wilks' Lambda
1	ESTC	1,000	61,546	
2	ESTC	,930	22,852	,593
	RCMCPD	,930	12,589	,525
3	ESTC	,889	11,353	,450
	RCMCPD	,908	14,276	,467
	EBITCT	,947	10,037	,442
4	ESTC	,852	6,569	,389
	RCMCPD	,905	11,550	,416
	EBITCT	,937	7,396	,394
	ESTA	,929	5,509	,384

Quanto mais próximo de 1 (um), maior é a independência de uma variável em relação as demais, enquanto um resultado 0 (zero) mostra o oposto.

A função computada pelo método passo a passo classificou corretamente 88,6% dos casos conforme quadro a seguir:

Matriz de Classificação - Método Passo a passo					
Situação	Grupos	Classificados a priori	Previstos	Classificação correta (%)	Acerto Total (%)
Original	0	35	31	88,60	88,6
	1	35	31	88,60	
Validação Cruzada	0	35	31	88,60	87,10
	1	35	30	85,70	

O teste Box's M apresentou p -valor 0,061, que comparado com o nível de significância de 5,0% ($\alpha = 0,05$) permite não rejeitar a hipótese (H_0) de igualdade das matrizes de variância-covariância (homocedasticidade) para os dois grupos.

Teste M de Box

Box's M		18,848
F	Approx.	1,765
	df1	10
	df2	22106,773
	Sig.	,061

4.12. Significância da Função Discriminante

Autovalores

Função	Autovalor	% da variância	total %	Correlação Canônica
1	1,828 ^a	100,0	100,0	,804

Lambda de Wilks

Função	Wilks' Lambda	Qui-Quadrado	df	Sig.
1	,354	68,616	4	,000

Com a existência de dois grupos em estudo, somente uma função foi estimada. O auto valor (medida relativa de quão diferentes são os grupos sob

estudo) associado a esta função foi 1,828 que responde por 100% da variância explicada. A correlação canônica – que mede o alcance da associação entre os escores discriminantes e os grupos, associada a função é 0,804 que elevada ao quadrado indica que 64% da variável dependente são explicadas pelo modelo. Com o resultado de 0,354 para o lambda de Wilks equivalente ao qui-quadrado de 68,616 e *p* – valor 0,000 podemos inferir que a função é altamente significativa.

5. Conclusão

A construção de um modelo de previsão de insolvência com utilização da análise discriminante e dados contábeis foi o objetivo principal deste estudo. O modelo proposto, derivado pelo método passo a passo, apresentou índice de acerto de 88,6%, valor superior a resultados de alguns modelos construídos no passado com a mesma técnica.

A inclusão de empresas com valor dos ativos menor que suas obrigações (patrimônio Líquido negativo), no grupo das empresas ruins foi uma abordagem diferenciada em relação aos trabalhos anteriores que consideravam como empresas insolventes somente aquelas com concordata ou falência decretada.

Os testes de normalidade (Kolmogorov-Smirnov) e homogeneidade (Levene) indicaram que as variáveis preditoras, selecionadas para compor a função discriminante pelo método passo a passo, cumpriram os principais pressupostos da análise discriminante e o teste M de Box indicou a existência de igualdade das matrizes de variância-covariância dos grupos. Estes resultados garantem a robustez do modelo proposto.

Com relação as variáveis independentes do modelo, EstA, Estc, EBITCT e RCMCPd, o estudo confirmou o poder discriminatório das primeiras três variáveis como nos trabalhos de Altman (1968), Altman (1979), Lo (1986), Sanvicente e Minardi (1998) e Glen (2004). Estas variáveis evidenciam, respectivamente, as decisões financeiras sobre estrutura de ativos, estrutura de capital e a geração de caixa.

A variável RCMCPd, representativa do montante dos recursos próprios disponíveis, também apresentou resultados satisfatórios. Esta variável é utilizada normalmente para avaliar se o montante de capital próprio das instituições financeiras é suficiente para a cobertura dos riscos assumidos por aquelas entidades. O resultado conseguido no presente trabalho, com empresas não financeiras, mostrou que a variável tem poder discriminante e pode ser usada como variável preditora da probabilidade de insolvência de firmas não financeiras.

Em resumo podemos afirmar, com base nos resultados apresentados, que o modelo proposto tem robustez estatística, representa, através das suas variáveis independentes, o resultado das decisões das firmas e tem bom índice de acerto nas predições o que o credencia como ferramenta importante na gestão de risco de crédito das empresas.

6. Bibliografia

BACK, B. et al. **Choosing bankruptcy predictors using discriminant analysis, logit analysis, and genetic algorithms.** Turku Centre for Computer Science Technical Report No 40. September 1996. ISBN 951-650-828-6. ISSN 1239-1891. p.p.1-5.

BARTH, Nelson Lerner. **Inadimplência: Construção de modelos de previsão.** São Paulo: Nobel. 2004. p.p.3, 10-15 e 21-30.

BUSSAB, Wilton de Oliveira; MORETTIN, Pedro Alberto. **Estatística básica.** 5ª. ed. São Paulo: Saraiva. 2003. p.343.

CARNEIRO, Fábio Lacerda. **Modelagem de risco de crédito de portfólio: implicações para a regulamentação sobre requerimento de capital de instituições financeiras.** Dissertação apresentada ao Curso de Pós-Graduação da FGV/EAESP, na área de concentração de Contabilidade, Finanças e Controle, como requisito para a obtenção do título de mestre em Administração. 2002. p.p.108-158.

CAOQUETTE, John B.; ALTMAN, Edward I.; NARAYANAM, Paul. **Gestão do risco de crédito: O próximo grande desafio do futuro.** Tradução de Allan Hastings. Supervisão técnica João Carlos Douat. Rio de Janeiro: Qualitymark. 1999. p.p.119-121 e 130-144.

CROUHY, Michel; GALLAI, Dan; MARK, Robert. **Gerenciamento de risco: abordagem conceitual e prática.** Tradução Carlos Henrique Trieschmann. Supervisão técnica João Carlos Douat. Série Serasa. Rio de Janeiro: Qualitymark. 2004. p.p.309-311 e 362.

DAMODARAN, Aswath. **Avaliação de Investimentos: Ferramentas e técnicas para a determinação do valor de qualquer ativo.** Tradução de Bazán Tecnologia e

Linguística. Supervisão Técnica Eduardo Fortuna. 1^a.ed. Rio de Janeiro: Qualitymark. 1997. p.49.

DUARTE Jr, Antonio Marcos. **Risco: Definições, tipos, medições e recomendações para seu gerenciamento.** Disponível em <http://www.risktech.com.br/PDFs/RISCO.pdf>. Acesso em: 30 jul. 2005, 12:11. p.16.

GIMENEZ, Régio Marcio Toesca; OPAZO, Miguel Angel Uribe. Previsão de Insolvência de Cooperativas Agropecuárias por Meio de Modelos Multivariados. **Revista FAE**, Curitiba, v.4, n.3, p.p.65-78, set./dez. 2001.

GITMAN, Lawrence Jeffrey. **Princípios de administração financeira.** Tradução Técnica Antonio Zoratto Sanvicente. São Paulo: Addison Wesley. 2004.

Glen, Jack. **Debit and firm vulnerability.** 2004. Disponível em http://www.defaultrisk.com/ps_scoring.htm. Acesso em: 21 set. 2005, 10:50. p.p.6-8.

HAIR Jr, et al. **Análise multivariada de dados.** Tradução Adonai Schlup Santánnia e Anselmo Chaves Neto. Supervisão técnica Maria Aparecida Gouvêa. 5a. edição. Porto Alegre: Bookman. 2005. p.p.80-87 e 209-230.

HARRIS, Milton; RAVIV, Artur. The Theory of Capital Structure. The Journal of Finance. Vol. 46. No. 1, mar/1991. p.p. 297-355.

LO, Andrew W. Logit versus Discriminant Analysis: A Specification Test With Application to Corporate Bankruptcies. **Journal of Econometrics**. Vol. 31. p.p.151-178. 1986..

MAROCO, João. **Análise estatística com utilização do SPSS.** 2^a. Edição. Lisboa: Silabo. 2003. p.p. 56-59, 112-114 e 332-360.

MARQUES, Jair Mendes., Lima, Donizetti d. A estatística multivariada na análise econômico-financeira de empresas. **Rev. FAE**, Curitiba, v.5, n.3, p.51-59, set./dez. 2002.

MATOS, João Amaro de, **Theoretical foundations of corporate finance**. New Jersey: Princeton University Press. 2001. p.p.79-81.

PAIVA, Carlos Alberto de Carvalho. **Administração do risco de crédito**. Rio de Janeiro: Qualitymark. 1997. p.3.

REQUIÃO, Rubens. **Curso de direito falimentar**. 17^a. Edição. São Paulo: Saraiva.1998. p.56.

SANVICENTE, Antonio Zoratto.; MINARDI, Andréa Maria A.F. **Identificação de indicadores contábeis significativos para previsão de concordata de empresas**. Disponível em: www.risktech.com.br/PDFs/indicadores_concordata.pdf. Acesso em: 15 ago. 2005. 09:21. p.p.1-3.

SECURATO, José Roberto. Um modelo para determinação do valor presente de uma carteira de crédito e de seu risco. Caso CDC – Crédito Direto ao Consumidor. In: **III SEMEAD – SEMINÁRIOS DE ADMINISTRAÇÃO DA FEA/USP**. 1988. p.3.

SERASA. Estudos Econômicos: Desempenho das Empresas Comerciais Brasileiras de 1994 a 2004 Vendas do Comércio crescem 4,5% em 2004 e expansão do crédito é a maior desde 2000. Disponível em <http://www.serasa.com.br/empresa/noticias>. Acesso em: 18 nov. 2004, 09:53.

SERASA. Estudos Econômicos: Crédito Mercantil de Curto Prazo é maior que Crédito Bancário. Disponível em <http://www.serasa.com.br/empresa/noticias>. Acesso em: 28. fev. 2006, 12:47.

SILVA, José Pereira da. **Gestão e análise de risco de crédito**. 4^a. Edição. São Paulo: Atlas. 2003. p.63.

ANEXOS

Tabela 1. Amostra de desenvolvimento.

EMPRESA	SETOR	CLASSIFICAÇÃO A PRIORI
Cor Ribeiro	Holdings	RUIM
Doc Imbituba	Agricultura	BOA
Fras-Le	Autopeças	RUIM
Randon Part	Autopeças	BOA
Buettner	Têxtil e Calçados	RUIM
Coteminas	Têxtil e Calçados	BOA
Pará Deminas	Têxtil e Calçados	RUIM
Guararapes	Têxtil e Calçados	BOA
SPSCS Indl	Metalúrgico	RUIM
La Fonte Tel	Metalúrgico	BOA
Lojas Arapuã	Comércio	RUIM
Lojas Americ	Comércio	BOA
MCOM Wireles	Telefonia Móvel	RUIM
Tim Sul	Telefonia Móvel	BOA
Celm	Máquinas e Equipamentos	RUIM
Confab	Máquinas e Equipamentos	BOA
Mundial	Metalúrgico	RUIM
Forja Taurus	Metalúrgico	BOA
Vulcabrás	Têxtil e Calçados	RUIM
Dohler	Têxtil e Calçados	BOA
Adubos Trevo	Agricultura	RUIM
Fosfértil	Agricultura	BOA
CPFL Energia	Serviços Públicos	RUIM
Comgás	Serviços Públicos	BOA
Linh Círculo	Têxtil e Calçados	RUIM
Lojas Renner	Comércio	BOA
Itaitinga	Outros	RUIM
Habitasul	Outros	BOA
Plascar Part	Autopeças	RUIM
Semp	Eleto-Eletrônico	BOA
Amelco	Eleto-Eletrônico	RUIM
Bergamo	Eleto-Eletrônico	BOA
Estrela	Brinquedos, Plásticos e Madeiras	RUIM
Duratex	Brinquedos, Plásticos e Madeiras	BOA
Aes Elpa	Serviços Públicos	RUIM
Tractebel	Serviços Públicos	BOA

EMPRESA	SETOR	CLASSIFICAÇÃO A PRIORI
BR Ferrovias	Transp. Aéreo/Ferroviário	RUIM
Grucai	Transp. Aéreo/Ferroviário	BOA
Celg	Serviços Públicos	RUIM
CEB	Serviços Públicos	BOA
D F Vasconc	Outros	RUIM
Inds Romi	Holdings	BOA
Arteb	Metalúrgico	RUIM
CBC Cartucho	Metalúrgico	BOA
Cremer	Têxtil e Calçados	RUIM
Encorpar	Têxtil e Calçados	BOA
Kuala	Têxtil e Calçados	RUIM
Cia Hering	Têxtil e Calçados	BOA
Ferroban	Transp. Aéreo/Ferroviário	RUIM
Ferbasa	Mineração	BOA
Verolme	Construção Civil	RUIM
Tecnosolo	Construção Civil	BOA
Paranapanema	Mineração	RUIM
Caraíba Met	Mineração	BOA
Aes Sul	Serviços Públicos	RUIM
Cemig	Serviços Públicos	BOA
Schlosser	Têxtil e Calçados	RUIM
SantisTextil	Têxtil e Calçados	BOA
Recrusul	Agricultura	RUIM
Santos Brasil	Agricultura	BOA
Eucatex	Plásticos e Madeiras	RUIM
Suzano	Papel e Celulose	BOA
Hopi Hari	Holdings	RUIM
Globex	Comércio	BOA
Inepar	Eleto-Eletrônico	RUIM
Brasmotor	Eleto-Eletrônico	BOA
Net	Comércio	RUIM
Drogasil	Comércio	BOA
Parmalat	Alimentos	RUIM
Bunge Brasil	Alimentos	BOA

Fonte: Banco de dados do Sistema de Análise de Balanços de Empresas – SABE/IBEMEC.

Tabela 2. Amostra de Validação

EMPRESA	SETOR	CLASSIFICAÇÃO A PRIORI
Sifco	Autopeças	RUIM
Metal Leve	Autopeças	BOA
Wetzel	Metalúrgico	RUIM
Fibam	Metalúrgico	BOA
Aço Altona	Siderúrgico	RUIM
Aliperti	Siderúrgico	BOA
Zivi	Metalúrgico	RUIM
Weg	Máquinas e Equipamentos	BOA
Jaraguá Fabr	Têxtil e Calçados	RUIM
Cedro	Têxtil e Calçados	BOA
Nordon	Máquinas e Equipamentos	RUIM
Marcopolo	Máquinas e Equipamentos	BOA
Bic Calói	Comércio	RUIM
Grazziotin	Comércio	BOA
Chapecó	Alimentos	RUIM
CTM Citrus	Alimentos	BOA
F Guimarães	Têxtil e Calçados	RUIM
Braspérola	Têxtil e Calçados	BOA
Tec Toy	Brinquedos, Plásticos e Madeiras	RUIM
Arthur Lange	Brinquedos, Plásticos e Madeiras	BOA
Rimet	Metalúrgico	RUIM
Riosulense	Metalúrgico	BOA
Ind Villares	Metalúrgico	RUIM
Metal Iguacu	Metalúrgico	BOA
Master	Brinquedos, Plásticos e Madeiras	RUIM
Sansuy	Brinquedos, Plásticos e Madeiras	BOA
Labo	Eleto-Eletrônico	RUIM
Multibrás	Eleto-Eletrônico	BOA
Sola	Alimentos	RUIM
Sadia	Alimentos	BOA
Melhor SP	Papel e Celulose	RUIM
Klabin	Papel e Celulose	BOA
Minupar	Alimentos	RUIM
Perdigão	Alimentos	BOA
Americel	Telefonia Móvel	RUIM
Albarus	Autopeças	BOA
Cambuci	Têxtil e Calçados	RUIM
Alpargatas	Têxtil e Calçados	BOA
Elektro	Serviços Públicos	RUIM
Copel	Serviços Públicos	BOA
Douat Textil	Têxtil e Calçados	RUIM
Karsten	Têxtil e Calçados	BOA
Wiest	Metalúrgico	RUIM
Tupy	Metalúrgico	BOA
Bombril	Comércio	RUIM
Bompreço Bah	Comércio	BOA

Fonte: Banco de dados do Sistema de Análise de Balanços de Empresas – SABE/IBEMEC.