



JOSÉ WILLER DO PRADO

**RISCO DE CRÉDITO: UMA ABORDAGEM
UTILIZANDO ANÁLISE DISCRIMINANTE,
REGRESSÃO LOGÍSTICA E REDES NEURAIAS
ARTIFICIAIS**

**LAVRAS – MG
2016**

JOSÉ WILLER DO PRADO

**RISCO DE CRÉDITO: UMA ABORDAGEM UTILIZANDO ANÁLISE
DISCRIMINANTE, REGRESSÃO LOGÍSTICA E REDES NEURAIS
ARTIFICIAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Administração, área de concentração em Gestão de Negócios, Economia e Mercados, para a obtenção do título de Mestre.

Orientador

Dr. Francisval de Melo Carvalho

**LAVRAS – MG
2016**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Prado, José Willer do.

Risco de crédito : uma abordagem utilizando análise discriminante, regressão logística e redes neurais artificiais / José Willer do Prado. – Lavras : UFLA, 2016.

228 p. : il.

Dissertação (mestrado acadêmico)–Universidade Federal de Lavras, 2016.

Orientador(a): Francisval de Melo Carvalho.

Bibliografia.

1. Modelo Dinâmico. 2. Modelo Fleuriet. 3. Risco de crédito. 4. Falências. 5. Indicadores financeiros. I. Universidade Federal de Lavras. II. Título.

JOSÉ WILLER DO PRADO

**RISCO DE CRÉDITO: UMA ABORDAGEM UTILIZANDO ANÁLISE
DISCRIMINANTE, REGRESSÃO LOGÍSTICA E REDES NEURAIS
ARTIFICIAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Administração, área de concentração em Gestão de Negócios, Economia e Mercados, para a obtenção do título de Mestre.

APROVADA EM 26 de fevereiro de 2016.

Dr. André Luis Ribeiro Lima UFLA

Dr. Fabrício Molicca de Mendonça UFSJ

Dr. Gideon Carvalho de Benedicto UFLA

Dr. Francisval de Melo Carvalho
Orientador

**LAVRAS – MG
2016**

À Mírian Rosa. La Perfection de la Nature.

DEDICO

AGRADECIMENTOS

Primeiramente, à Deus por propiciar as condições necessária à conquista de mais este objetivo. À toda minha família pelo apoio incondicional e, especialmente, à minha vovó Ceci Lopes por me ajudar de forma efetiva, durante todo este período em que estive à disposição do mestrado, sem o seu apoio, talvez, não pudesse colher todos os frutos desta etapa.

Ao meu Orientador Professor Francisval de Melo Carvalho, por acreditar em nossa proposta de trabalho e me conduzir de forma lúcida e clara até o termino desta dissertação. Mesmo quando eu apresentava ideias confusas sobre os caminhos teóricos e metodológicos a seguir, o Professor Francisval sempre me direcionava com muita paciência e da melhor forma possível para que eu encontrasse os melhores caminhos nesta jornada.

À Universidade Federal de Lavras (UFLA) e ao Departamento de Administração e Economia (DAE), pela oportunidade concedida para realização do mestrado. À CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pela concessão da bolsa de estudos durante todo o período de realização do mestrado.

Refaço os agradecimentos feitos, em meu TCC, à Professora Fabíola Adriane Cardoso Santos, por me introduzir neste fantástico mundo dos modelos matemáticos e à Professora Adriana Giarola Vilamaior, com quem desenvolvi o gosto pelas Demonstrações Financeiras e pela análise de Balanços. Neste mesmo âmbito, incluo o querido professor Gideon Carvalho de Benedicto com quem tive a oportunidade de conviver neste período e aprofundar um pouco mais no conhecimento das Demonstrações Financeiras.

À querida Laís Teixeira Silva pelo apoio durante o período que realizei o processo seletivo para o mestrado na UFLA e todo incentivo. Aos meus caríssimos amigos, André Spuri Garcia e Luís Fernando Silva Andrade, por me auxiliarem com as revisões. Ao meu querido amigo, Mário Sérgio de Almeida, pela ajuda com o Banco de Dados, ao grande Janderson Martins Vaz por me ajudar com a classificação das contas das demonstrações financeiras.

E, por fim, não poderia faltar aqueles que considero já da família, o nobre Alex dos Santos Macedo quem me acolheu em Lavras e me auxiliou de forma magnífica e, também, um irmão não menos nobre Valderí de Castro Alcântara com quem aprendi e aprendo muito e, também, à minha querida Kelly Carvalho Vieira por todos os bons momentos e todo apoio. Sem contar nas nossas tardes com cafés (Alex) que foram, além de produtivas, extraordinárias.

Devo admitir que maior parte do meu mestrado se constituiu em uma busca constante para ser aprovado no doutorado, mas são outros agradecimentos, estes não menos importantes, guardo-os para a tese, pois sei que lá eles farão mais sentido do que aqui!

Obrigado!

“Uma longa viagem começa com um único passo”.

Lao-Tsé (604-531 a.C.)

RESUMO

Diante da relevância das pesquisas sobre risco de crédito, da diversidade de modelos e indicadores existentes, esta dissertação objetivou verificar se o Modelo Fleuriet contribui para discriminação de empresas brasileiras de capital aberto na análise de concessão de crédito. Especificamente, pretendeu-se i) identificar os indicadores econômico-financeiros utilizados em modelos de risco de crédito; ii) identificar quais indicadores econômico-financeiros melhor discriminam empresas na análise de concessão de crédito e iii) aferir quais das técnicas utilizadas (análise discriminante, regressão logística e redes neurais) apresentam melhor acurácia para prever a falência empresarial. Para tanto, o referencial teórico abordou conceitos de análise financeira que introduziram temas relativos ao processo de avaliação empresarial; considerações sobre o crédito, risco e análise; Modelo Fleuriet e seus indicadores e, por fim, apresentaram-se as técnicas para análise de crédito baseadas em análise discriminante, regressão logística e redes neurais artificiais. Metodologicamente, a pesquisa foi definida como quantitativa quanto à natureza e explicativa quanto ao tipo e desenvolvida por meio de dados oriundos de pesquisa bibliográfica e documental. As demonstrações financeiras foram coletadas por meio do Economática[®] e do site BM&FBOVESPA. A amostra foi composta por 121 empresas, sendo 70 solventes e 51 insolventes de diversos setores. Nas análises foram utilizados 22 indicadores do Modelo Tradicional e 13 do Modelo Fleuriet, totalizando 35. Os indicadores econômico-financeiros que fizeram parte de pelo menos um dos três modelos finais foram: X1 (Capital de Giro sobre Ativo), X3 (NCG sobre Ativo), X4 (NCG sobre Receita líquida), X8 (Tipo de Estrutura Financeira), X9 (Termômetro de liquidez), X16 (Patrimônio líquido dividido pelo exigível total), X17 (Giro do ativo), X20 (Rentabilidade do Patrimônio Líquido), X25 (Margem Líquida), X28 (Composição do Endividamento) e X31 (Patrimônio líquido sobre ativo). Os modelos finais apresentaram valores de acerto: 90,9% (análise discriminante); 90,9% (regressão logística) e 97,8% (redes neurais). A modelagem em redes neurais apresentou maior acurácia, o que também foi confirmado pela curva ROC. Conclui-se que os indicadores, do Modelo Fleuriet apresentaram resultados relevantes, para as pesquisas de risco de crédito, especialmente, se modelados por meio de redes neurais.

Palavras-chave: Modelo Dinâmico. Modelo Fleuriet. Risco de crédito. Falências. Indicadores financeiros.

ABSTRACT

Considering the relevance of researches concerning credit risk, model diversity and the existent indicators, this thesis aimed at verifying if the Fleuriet Model contributes in discriminating Brazilian open capital companies in the analysis of credit concession. We specifically intended to i) identify the economic-financial indicators used in credit risk models; ii) identify which economic-financial indicators best discriminate companies in the analysis of credit concession; iii) assess which techniques used (discriminant analysis, logistic regression and neural networks) present the best accuracy to predict company bankruptcy. To do this, the theoretical background approached the concepts of financial analysis, which introduced themes relative to the company evaluation process; considerations on credit, risk and analysis; Fleuriet Model and its indicators, and, finally, presented the techniques for credit analysis based on discriminant analysis, logistic regression and artificial neural networks. Methodologically, the research was defined as quantitative, regarding its nature, and explanatory, regarding its type. It was developed using data derived from bibliographic and document analysis. The financial demonstrations were collected by means of the Economática[®] and the BM\$FBOVESPA website. The sample was comprised of 121 companies, being those 70 solvents and 51 insolvents from various sectors. In the analyses, we used 22 indicators of the Traditional Model and 13 of the Fleuriet Model, totalizing 35 indicators. The economic-financial indicators which were a part of, at least, one of the three final models were: X1 (Working Capital over Assets), X3 (NCG over Assets), X4 (NCG over Net Revenue), X8 (Type of Financial Structure), X9 (Net Thermometer), X16 (Net Equity divided by the total demandable), X17 (Asset Turnover), X20 (Net Equity Profitability), X25 (Net Margin), X28 (Debt Composition) and X31 (Net Equity over Asset). The final models presented setting values of: 90.9% (discriminant analysis); 90.9% (logistic regression) and 97.8% (neural networks). The modeling in neural networks presented higher accuracy, which was confirmed by the ROC curve. In conclusion, the indicators of the Fleuriet Model presented relevant results for the research of credit risk, especially if modeled by neural networks.

Keywords: Dynamic Model. Fleuriet Model. Credit Risk. Bankruptcy. Financial Indicators.

LISTA DE FIGURAS

Figura 1	Representação do Crédito.....	28
Figura 2	Resumo dos 5 Cs do Crédito	29
Figura 3	Necessidade de Integração do Modelo Tradicional e do Modelo Fleuriet	44
Figura 4	Representação gráfica do Efeito Tesoura.....	52
Figura 5	Representação gráfica da análise discriminante de dois grupos.....	64
Figura 6	Amostra de tamanhos iguais.....	66
Figura 7	Amostra de tamanhos diferentes.....	67
Figura 8	Identificação da área de penumbra, nas distribuições dos grupos.....	69
Figura 9	Função Sigmoide	72
Figura 10	Exemplos de ajuste da curva logística a dados de amostra	73
Figura 11	Modelo não linear de um neurônio	79
Figura 12	Funções de Ativação	82
Figura 13	Esquema do mapeamento sucessivo em camadas realizado por uma rede PLP	86
Figura 14	Fluxo de processamento do algoritmo <i>back-propagation</i>	87

LISTA DE GRÁFICOS

Gráfico 1	Distribuição por grupos.....	142
Gráfico 2	Termômetro da insolvência.....	143
Gráfico 3	Arquitetura <i>feedforward</i> com uma camada oculta.....	156
Gráfico 4	Importância dos indicadores independentes.....	158
Gráfico 5	Distribuição das frequências acumuladas para KS para os modelos construídos (a = Análise Discriminante; b = Regressão Logística e c = Redes Neurais).....	169
Gráfico 6	Curva ROC para os três modelos apresentados.....	171

LISTA DE QUADROS

Quadro 1	Síntese dos modelos anteriores de previsão de insolvência.....	35
Quadro 2	Os ciclos no Balanço Patrimonial	46
Quadro 3	Síntese de trabalhos que utilizaram o Modelo Fleuriet	58
Quadro 4	Amostra de Empresas solventes e insolventes.....	97
Quadro 5	Indicadores do Modelo Fleuriet.....	105
Quadro 6	Indicadores do Modelo Tradicional	106
Quadro 7	Notação das Fórmulas de Cálculo dos Indicadores	108
Quadro 8	Parâmetros das configurações realizadas	152
Quadro 9	Resumo dos resultados para o indicador X3- NCG/AT, X4- NCG/RL e X11- NCG.....	178
Quadro 10	Resumo dos resultados para o indicador X8 – Tipo de Estrutura Financeira.....	181
Quadro 11	Resumo dos resultados para o indicador X9 – TL e X10) T ...	183
Quadro 12	Resumo dos resultados para o indicador X16 – Patrimônio Líquido/Exigível Total.....	185
Quadro 13	Resumo dos resultados para o indicador X17 – Giro do ativo	186
Quadro 14	Resumo dos resultados para o indicador X20 – Rentabilidade do PL.....	188
Quadro 15	Resumo dos resultados para o indicador X25 – Margem Líquida	190
Quadro 16	Resumo dos resultados para o indicador X28 – Composição do Endividamento	191
Quadro 17	Resumo dos resultados para o indicador X31 – Patrimônio líquido sobre ativo	192

LISTA DE TABELAS

Tabela 1	Tipos de estrutura e situação financeira	54
Tabela 2	Poder discriminante: valores de referência da literatura	93
Tabela 3	Distribuição das empresas por setor de atuação	102
Tabela 4	Estatística Descritiva dos Indicadores.....	113
Tabela 5	ANOVA de um fator (One-Way)	119
Tabela 6	Comunalidades FATORIAL 01.....	123
Tabela 7	Variância total explicada FATORIAL 01	125
Tabela 8	Matriz de componente rotativa FATORIAL 01	127
Tabela 9	Comunalidades FATORIAL 02.....	130
Tabela 10	Variância total explicada FATORIAL 02	132
Tabela 11	Matriz de componente rotativa FATORIAL 02	134
Tabela 12	Resultado da sexta etapa do método <i>stepwise</i>	136
Tabela 13	Testes de igualdade de médias de grupo	137
Tabela 14	Matriz de correlação entre as indicadores independentes	138
Tabela 15	Coeficientes para multicolinearidade.....	139
Tabela 16	Coeficientes de função discriminante canônica.....	140
Tabela 17	Resultados da classificação ^{a,b,d}	145
Tabela 18	Testes de Cox Snell e Nagelkerke	147
Tabela 19	Teste de Hosmer e Lemeshow.....	147
Tabela 20	Classificação ^a Regressão Logística.....	148
Tabela 21	Coeficientes para multicolinearidade.....	149
Tabela 22	Indicadores na equação	149
Tabela 23	Informações de rede.....	154
Tabela 24	Resumo do modelo	160
Tabela 25	Percentual de classificação das redes neurais artificiais	160

Tabela 26	Estimativas do parâmetro (Matrizes de coeficientes ou pesos de conexão)	162
Tabela 27	Comparação dos modelos com indicadores diferentes por modelo.....	164
Tabela 28	Acurácias obtidas pelos três modelos finais (aos níveis de erro tipo I e tipo II)	166
Tabela 29	Cálculo da estatística KS para os escores do modelo de Análise Discriminante.....	166
Tabela 30	Cálculo da estatística KS para os escores do modelo de Regressão Logística	167
Tabela 31	Cálculo da estatística KS para os escores do modelo de Redes Neurais Artificiais	168
Tabela 32	Estatísticas de teste KS para os modelos construídos	170
Tabela 33	Área sob a curva	172
Tabela 34	Medidas de desempenho para os modelos gerados.....	173
Tabela 35	Indicadores selecionados.....	175
Tabela 36	Agrupamento de empresas por tipos de estrutura e situação financeira.....	179

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Questão de pesquisa	19
1.2	Objetivos.....	19
1.2.1	Objetivo geral.....	19
1.2.2	Objetivos específicos.....	19
1.3	Justificativa da Pesquisa	20
2	REFERENCIAL TEÓRICO	22
2.1	Análise das Demonstrações Financeiras.....	22
2.2	Crédito	24
2.2.1	Risco de crédito.....	30
2.2.2	A análise quantitativa do crédito.....	33
2.3	O Modelo Fleuriet	43
2.3.1	O Balanço Patrimonial no Modelo Fleuriet	45
2.3.2	Os principais indicadores que compõem o modelo.....	48
2.3.3	Análise de crédito e o Modelo Fleuriet	56
2.4	Técnicas para análise de crédito.....	62
2.4.1	Análise discriminante - AD	62
2.4.2	Regressão logística - RL.....	71
2.4.3	Redes neurais artificiais - RNA.....	77
2.4.4	Avaliação dos modelos.....	91
3	METODOLOGIA	94
3.1	Tipo de pesquisa.....	94
3.2	Amostragem.....	95
3.3	Definição dos indicadores.....	103
4	RESULTADOS E DISCUSSÃO	112
4.1	Análise Fatorial.....	121

4.2	Análise discriminante - AD	136
4.3	Regressão logística - RL.....	146
4.4	Redes neurais artificiais - RNA.....	151
4.5	Comparação dos modelos	163
4.6	Análise dos Indicadores.....	173
4.6.1	Capital de Giro sobre Ativo (X1- CDG / AT).....	176
4.6.2	Necessidade de Capital de Giro (X3- NCG/AT), (X4- NCG/RL) e (X11- NCG).....	177
4.6.3	Tipo de Estrutura Financeira (X8- TEF = Estrutura do balanço)....	180
4.6.4	Termômetro de liquidez e o Saldo de Tesouraria (X09- TL e X10- T).....	182
4.6.5	Patrimônio Líquido sobre Exigível Total (X16- PL / ET).....	184
4.6.6	Giro do ativo (X17- RL / AT).....	186
4.6.7	Rentabilidade do Patrimônio Líquido (X20- LL / PL).....	187
4.6.8	Margem Líquida (X25 - LL / RL).....	189
4.6.9	Composição do Endividamento (X28- PC / (PC + PNC)).....	190
4.6.10	Patrimônio líquido sobre ativo (X31- PL / AT).....	192
5	CONCLUSÃO	194
	REFERÊNCIAS.....	199
	APÊNDICES	216

1 INTRODUÇÃO

As decisões referentes à concessão ou não de crédito tem papel fundamental para as instituições credoras. O discernimento entre quais fatores levam ao fracasso empresarial e quais são indicativos de solvência podem ser o limiar entre o lucro ou a perda do investimento. Nesse sentido, observa-se que o estudo de metodologias e ferramentas que auxiliam o fornecimento do crédito possui grande importância, tanto de ordem econômica¹ quanto social.

Quando o volume de operações de crédito é alto, torna-se imprescindível para os gestores considerar o risco envolvido, sendo o risco um custo sempre presente nos negócios de crédito e, portanto necessário quantificá-lo. De forma mais específica, a ideia de risco está associada à probabilidade de que ocorra determinado resultado em relação ao retorno esperado. Assim, está voltado para o futuro, revelando uma possibilidade de perda (ASSAF NETO, 2010). Nas atividades financeiras envolvendo crédito busca-se encontrar segurança contra o risco presente nas operações ou, no mínimo, transformar a incerteza em risco mensurável (SILVA, 1983).

Evidencia-se que as primeiras pesquisas neste campo buscavam detectar se os indicadores das empresas solventes eram favoráveis e se os indicadores das empresas insolventes eram desfavoráveis. Um dos primeiros estudos (univariados), realizados no campo, foi *The Use of Multiple Measurements in Taxonomic Problems* de Fisher (1936) e *Risk Elements in Consumer Installment Lending* de Durand (1941). Entretanto as análises univariadas, realizadas no final da década de 1950, foram substituídas assim que as pesquisas acadêmicas

¹ Para destacar isso observa-se que, segundo o Banco Central do Brasil - BACEN (2015) o saldo das operações de crédito do sistema financeiro Brasileiro totalizou R\$3,3 trilhões em fevereiro de 2015, com aumento de 11,0% em doze meses. O estoque de crédito atingiu R\$1,60 trilhões no segmento de pessoas jurídicas, com aumento de 9,6%. A relação crédito/PIB atingiu 58,6% (57,9% em novembro e 55,5% em fevereiro de 2014).

se voltaram para técnicas de modelagem de *credit scoring* no final da década de 1960 (SABATO, 2009).

Os trabalhos seminais neste campo foram o *Financial ratios predictors of failure* de Beaver (1966) e *Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy* de Altman (1968). Esses dois estudos iniciaram as pesquisas com a *multivariate discriminant analysis (análise discriminante multivariada)*, técnica esta que viria a ser bastante utilizada nas pesquisas sobre a temática até Ohlson (1980) realizar um estudo chamado *Financial ratios and the probabilistic prediction of bankruptcy*, utilizando o modelo *logit* para a previsão de inadimplência, abrindo uma perspectiva para a utilização de outras metodologias no campo de estudo. Uma década depois, Odom e Sharda (1990), com o trabalho *A Neural Network Model for Bankruptcy Prediction*, propuseram um novo modelo, desta vez fundamentado nas técnicas de inteligência artificial conhecidas como *artificial neural networks*.

No Brasil, o primeiro estudo foi o artigo “Como prever falências de empresas”, publicado pelo professor Stephen Charles Kanitz e que utiliza análise discriminante e regressão múltipla. Kanitz (1974) propôs um termômetro da situação de solvência empresarial que se tornaria referência para pesquisas futuras. Outras pesquisas que se tornariam relevantes para o campo foram: o trabalho “Um modelo matemático para decisões de crédito no banco comercial”, desenvolvido por Elizabetsky (1976) e “Contribuição às técnicas de análise financeira: um modelo de concessão de crédito”, elaborado por Matias (1978) entre outros.

Atualmente existem diversas ferramentas que se propõem à análise do crédito. As mais tradicionais, na construção de modelos de risco de crédito, são as técnicas de análise multivariada como, por exemplo, a análise discriminante e a regressão logística. Contudo, técnicas de inteligência artificial têm despertado a atenção dos pesquisadores para novas possibilidades (ABIYEV, 2014;

CASTRO JUNIOR, 2003; CHUANG; HUANG, 2011; KIM, 2011; LI; LIU; QI, 2007; TAM, 1991).

Martins (2003) explana que a literatura financeira não determina quais os indicadores são mais expressivos na avaliação da insolvência. Segundo o autor, mesmo que muitos indicadores sejam empregados de forma recorrente em vários estudos, a escolha dos indicadores, em grande parte, está relacionada ao acesso aos dados e à percepção do pesquisador.

O primeiro estudo que buscou ampliar a gama de opções na escolha de novos indicadores econômicos/financeiros além daqueles referentes ao Modelo Tradicional de Análise Financeira, frequentemente, utilizados para a análise do risco de crédito no Brasil, foi o trabalho de Sanvicente e Minardi (1998), ao selecionarem indicadores do Modelo Fleuriet de Análise Financeira (também denominado como modelo dinâmico), para testar a dinâmica do *overtrading*, utilizando os indicadores ‘necessidade de capital de giro’ e ‘saldo de tesouraria’, como proposto por Fleuriet et al. (1978).

Apesar de Sanvicente e Minardi (1998) não terem encontrado melhores resultados ao substituir o índice de liquidez pelos indicadores da dinâmica do *overtrading*, os autores abriram possibilidades para que novos trabalhos explorassem outros indicadores. Brasil e Brasil (2008) salientam que o importante nem sempre é contrapor o Modelo Tradicional de Análise Financeira e o Modelo Fleuriet de Análise Financeira, mas, sim, buscar possibilidade de integração que resultasse em uma maior acurácia para as análises.

Diante do exposto, busca-se, no presente estudo, utilizar os indicadores do Modelo Tradicional e do Modelo Fleuriet de análise financeira para construir, utilizando as técnicas de análise discriminante, regressão logística e redes neurais artificiais, modelos capazes de avaliar o risco de crédito em empresas brasileiras de capital aberto. A escolha de duas metodologias de análise

financeira busca atingir a necessidade de integração do Modelo Tradicional ao Modelo Fleuriet como proposto por Brasil e Brasil (2008).

1.1 Questão de pesquisa

O Modelo Tradicional e o Modelo Fleuriet de análise financeira contribuem para uma melhor acurácia na análise da concessão de crédito para empresas brasileiras de capital aberto?

1.2 Objetivos

1.2.1 Objetivo geral

Verificar se o Modelo Tradicional e o Modelo Fleuriet de análise financeira contribuem para discriminação de empresas brasileiras de capital aberto na análise de concessão de crédito.

1.2.2 Objetivos específicos

- a) Verificar os indicadores econômico-financeiros utilizados em modelos de risco de crédito.
- b) Identificar quais indicadores econômico-financeiros melhor discriminam empresas na análise de concessão de crédito.
- c) Aferir quais das técnicas utilizadas (análise discriminante, regressão logística e redes neurais artificiais) apresentam melhor acurácia para prever a falência empresarial.

1.3 Justificativa da Pesquisa

A pesquisa se justifica, dentre outros fatores, pela relevância do tema para o estudo das Finanças Corporativas e pelo papel fundamental que o crédito desempenha para as empresas que utilizam de capital de terceiros para manter suas atividades. Apesar do número crescente de pesquisas sobre risco de crédito e falência (*credit risk e bankruptcy*), estudos que empregam o Modelo Fleuriet, dentro desta temática, ainda, são incipientes no Brasil – e não se conhece, até o presente momento, pesquisas no exterior.

A relevância do estudo é reforçada, também, pela carência de pesquisas que utilizam o Modelo Fleuriet para análise do risco de crédito. Neste sentido, o aprofundamento da utilização dos indicadores do Modelo Fleuriet, que proporcionem contribuições na acurácia das previsões dos modelos, diminuindo os riscos envolvidos e tornando as análises menos subjetivas, são basilares para o campo de pesquisa. Ainda que na avaliação da insolvência empresarial não exista um único modelo capaz de ser utilizado por todos os setores por um período indeterminado de tempo, novos modelos de análise podem apresentar bons resultados.

Como salienta Castro Junior (2003, p. 5), em grande parte da literatura encontrada, especialmente no Brasil, “[...], são poucos os estudos realizados nesta área, seja por falta de dados adequados a um estudo dessa natureza, seja pela crença de que indicadores contábeis não oferecem grande confiabilidade para a análise de risco de crédito de empresas”. Neste sentido, o aperfeiçoamento das metodologias utilizadas, assim como a evolução das técnicas de previsão, auxiliam os responsáveis pela organização a manter a liquidez empresarial, evitando uma situação de inadimplência ou até mesmo falência. Também possibilita aos gerentes de crédito buscar empresas saudáveis

que sejam capazes de cumprir com suas obrigações, evitando, assim, perda do capital investido e um melhor direcionamento dos recursos.

No que concerne ao mercado, a falência de uma organização incorre em grandes problemas tanto no que diz respeito à perda do capital investido, como no prejuízo social causado pelo evento. Um exemplo é o desemprego, perante a falta de capacidade da organização falida, para assumir suas obrigações para com todos os seus *stakeholders*. Logo, a pesquisa apresenta relevância para diversos segmentos da sociedade e é tema de interesse não apenas para o meio empresarial mas também para pesquisadores, investidores, profissionais da área de investimentos, credores, analistas financeiros e demais *stakeholders*. Isto se deve ao fato da temática contribuir, para a elucidação dos indicadores de financiamento, o que possibilita avaliar a solvência das companhias abertas brasileiras e, conseqüentemente, interfere no acesso ao financiamento.

De uma perspectiva acadêmica, o estudo da solvência das empresas é importante, para o fortalecimento da linha de pesquisa em finanças, dada uma melhor compreensão do comportamento das empresas e suas estratégias de financiamento. Por meio dessa proposta de pesquisa, pretende-se contribuir com a ampliação de conhecimentos a respeito da análise teórica e empírica sobre risco de crédito e sua potencial utilidade para o aprimoramento das decisões empresariais no mercado de capital no Brasil.

2 REFERENCIAL TEÓRICO

Com intuito de elucidar o tema proposto, o presente referencial está dividido em um primeiro tópico definido como análise financeira que introduz conceitos relativos sobre o processo de avaliação empresarial. A seguir, apresenta-se um tópico que traz considerações sobre o crédito, seu risco e análise, contendo, ainda, um histórico do desenvolvimento da análise de crédito. Aborda, também, o Modelo Fleuriet, seu conceito, os principais indicadores que compõem o modelo e sua aplicação na análise de crédito. Por fim, apresenta as técnicas para a análise de crédito abordadas no presente trabalho: análise discriminante; regressão logística; redes neurais artificiais; e os métodos para a avaliação das técnicas, tais como curva ROC e o índice Kolmogorov Smirnov - KS.

2.1 Análise das Demonstrações Financeiras

Para Silva (2012, p. 4, grifo nosso), a “análise financeira precisa ter um enfoque holístico, abrangendo a **estratégia** da empresa, suas decisões de **investimento** e de **financiamento** e suas **operações**”. O autor, ainda, afirma que a análise financeira da empresa consiste em uma apreciação minuciosa de todos os dados financeiros referentes à empresa, assim como das condições endógenas que comprometem, financeiramente, sua sobrevivência.

Marion (2012) destaca que a Análise das demonstrações financeiras é fundamental para o entendimento da situação econômico-financeira da empresa. Matarazzo (2010, p. 3) salienta que “a análise de Balanços objetiva extrair informações das Demonstrações Financeiras para a tomada de decisões”. Sebastião (2014, p. 4) indica que “talvez por essa razão, as demonstrações

financeiras divulgadas pelas entidades têm sido objeto de diversos estudos”. De forma ampla, a Análise das Demonstrações Financeiras se apresenta como uma ferramenta de apoio à tomada de decisão de natureza gerencial, como no caso das aplicações com base na temática risco de crédito desenvolvida nesta dissertação (GARCIA; GIMENEZ; GUIJARRO, 2013; HARRIS, 2013; KOU; WU, 2014; PEDERZOLI; THOMA; TORRICELLI, 2013; VAROTTO, 2012).

Segundo Sebastião (2014, p. 1):

As demonstrações financeiras são importantes e uteis no sentido em que auxiliam os *stakeholders* na obtenção de informações financeiras. Por isso, deverão estar disponíveis de forma a contribuir para a resposta às necessidades informativas dos gestores e outros agentes tomadores de decisão. No entanto, é imprescindível que a informação contemple um conjunto de características qualitativas, em especial a compreensibilidade, a tempestividade, a relevância, a fiabilidade e a comparabilidade, de forma a não comprometer a sua utilidade.

Segundo Assaf Neto (2012, p. 44), “a maneira com que os indicadores de análise são utilizados é particular de quem faz a análise, sobressaindo-se, além do conhecimento técnico, a experiência e a própria intuição do analista. Dois analistas podem chegar a conclusões bem diferentes sobre uma empresa, mesmo tendo eles trabalhado com as mesmas informações e utilizadas iguais técnicas de análise”. Para Iudícibus (2014, p. 5), a análise de balanços é “[...] a arte de saber extrair relações úteis, para o objetivo econômico que tivermos em mente, dos relatórios contábeis tradicionais e de suas extensões e detalhamentos, se for o caso”. E, ainda:

O analista de balanços preocupa-se com as demonstrações financeiras que, por sua vez, precisam ser transformadas em informações que permitam concluir se a empresa merece ou não crédito, se vem sendo bem ou mal administrada, se tem

ou não condições de pagar suas dívidas, se é ou não lucrativa, se vem evoluindo ou regredindo, se é eficiente ou ineficiente, se irá falir ou se continuará (MATARAZZO, 2010, p. 5).

Padoveze e Benedicto (2010) salientam que a análise de balanços consiste em um processo de avaliação da situação econômica, financeira, operacional e de rentabilidade da empresa, sendo o objetivo geral obter elementos para avaliar o processo de continuidade operacional e financeira da empresa. Nava (2009) corrobora afirmando que a análise das demonstrações contábeis por meio da criação de indicadores facilita o processo de tomada de decisões de investimento, financiamento e operacionais, uma vez que fornece informações sobre a eficiência das operações da empresa e sua situação econômico-financeira.

Kimura et al. (2008) complementam que comumente utiliza-se a análise tradicionalista das demonstrações contábeis para estimar a capacidade de crédito dos emissores. Neste sentido, a análise do risco de crédito, para empresas desenvolvidas no presente estudo, considera a apreciação das demonstrações contábeis com intuito de dar suporte a instituições credoras na concessão de crédito.

2.2 Crédito

Soares e Rebouças (2015) afirmam que o conceito de insolvência não é definido de forma clara na maioria das pesquisas. Segundo os autores, existe uma multiplicidade de episódios que podem ser indicados como estado de insolvência para uma empresa.

Ross, Westerfield e Jaffe (2009) enumeram algumas características da insolvência empresarial: i) redução de dividendos; ii) fechamento de unidades; iii) prejuízos; iv) dispensa de funcionários; v) renúncia de presidentes; vi) quedas substanciais do preço da ação.

Castro Junior (2003) complementa que, muitas vezes, os termos dificuldade financeira e insolvência são empregados na literatura de modo indiscriminado. Contudo, observa que alguns autores conseguem diferenciar de forma clara essas condições que podem se encontrar nas empresas. Neste contexto, Altman e Hotchkiss (2006) salientam que os problemas econômicos envolvendo empresas têm sido definidos de várias maneiras. No entanto, quatro nomenclaturas são utilizadas mais corriqueiramente na literatura: *failure*, *insolvency*, *default* e *bankruptcy* (ALTMAN; HOTCHKISS, 2006). Embora estes termos sejam, muitas vezes, usados como sinônimos, eles são distintamente diferentes no seu uso formal.

O conceito de *failure*, segundo Altman e Hotchkiss (2006), significa que a taxa realizada de retorno sobre o capital investido é, significativa e continuamente menor do que as taxas em vigor de investimentos semelhantes. Isto é, o retorno médio sobre investimento é continuamente abaixo do custo de capital da empresa. Estas situações econômicas não fazem declarações sobre a existência ou descontinuidade da entidade. Note-se que uma empresa pode ser um fracasso econômico, durante muitos anos, mas nunca deixa de cumprir suas obrigações contratuais.

Outra condição corporativa associada é o *default*, que ocorre, quando o devedor viola uma condição de um acordo com o credor, o qual pode ser motivado a iniciar uma ação legal. Considerado como uma insolvência técnica e de caráter temporária, esse *default* é, geralmente, utilizado para sinalizar o baixo desempenho da empresa. Raramente essas violações acarretam em um processo formal de falência (ALTMAN; HOTCHKISS, 2006).

Em seguida, Altman e Hotchkiss (2006) observam que a insolvência (*insolvency*) no sentido de falência (*bankruptcy*) é mais crítica e, geralmente, indica uma doença crônica e não uma condição temporária. A empresa encontra-se nesta situação quando o seu passivo total exceder uma avaliação justa de seus ativos totais. O patrimônio líquido real da empresa, portanto, é negativo. A insolvência técnica (*technical insolvency*), que seria a falta de liquidez da empresa que impossibilitaria o cumprimento de suas obrigações, é facilmente detectável e pode ser apenas uma condição temporária. Contudo, a condição mais grave é a falência (*bankruptcy*) que exige uma análise de avaliação abrangente a qual é realizada, geralmente, apenas com a contemplação de todos os ativos para liquidação.

Soares e Rebouças (2015, p. 41) destacam que “uma das aplicações mais conhecidas da previsão de insolvência é auxiliar na redução do risco de crédito”.

Nesse sentido, a capacidade de prever insolvência tem papel fundamental. Do ponto de vista econômico, diz-se que uma companhia está insolvente quando o total de seu passivo é superior ao seu ativo, ou seja, quando ela não pode pagar todas as dívidas assumidas mesmo com a liquidez total de seus bens e direitos. Por isso, estabelecer com antecedência quais empresas apresentam propensão à insolvência e quais são financeiramente saudáveis, é de vital importância para credores e para investidores (SOARES; REBOUÇAS, 2015, p. 42).

Em virtude da importância do tema para a economia como um todo, existem vários autores que fazem considerações sobre o crédito. Uma das definições mais encontradas em trabalhos sobre crédito é de autoria de Schrickel (2000, p. 25), que, assim, o define:

Crédito é todo ato de vontade ou disposição de alguém de destacar ou ceder, temporariamente, parte de seu patrimônio a um terceiro, com a expectativa de que esta parcela volte a

sua posse integralmente, depois de decorrido o tempo estipulado. Essa parte do patrimônio pode ser materializada por dinheiro (empréstimo monetário) ou bens (empréstimo para uso, ou venda com pagamento parcelado, ou a prazo).

A palavra crédito, para Silva (2008), compreende vários significados, dependendo unicamente do contexto em que é utilizada. Porém, em sentido mais restrito, o autor considera que crédito é a entrega de um montante (valor presente) mediante uma promessa de pagamento. Ainda, segundo o autor, um exemplo é o Banco, que tem a intermediação financeira como sua principal atividade. O crédito consiste, neste caso, em colocar à disposição do cliente (tomador de recursos) certo valor, na forma de empréstimo ou financiamento, mediante a promessa de quitação desta dívida, em certa data futura, visando auferir juros.

Segundo Assaf Neto e Silva (2012), crédito diz respeito à troca de bens presentes por bens futuros. Os autores complementam que, quando uma empresa concede crédito, troca produtos por uma promessa de pagamento futuro. Por outro lado, uma empresa que obtém crédito recebe produtos e assume o compromisso de efetuar o pagamento no futuro.

Portanto, na concessão de crédito, a empresa terá de responder “sim” ou “não” ao cliente e, caso a resposta seja positiva, deverá responder “até quando”. Novamente, o critério norteador da decisão será a maximização da riqueza da empresa, levando-se também em consideração o risco envolvido (ASSAF NETO; SILVA, 2012, p. 140).

O crédito é um ato de vontade e sempre caberá ao cedente do patrimônio a decisão final de concedê-lo ou não ao tomador (SCHRICKEL, 2000). Esta relação entre as partes atuantes no processo é ilustrada na Figura 1, identificando o significado restrito do crédito.

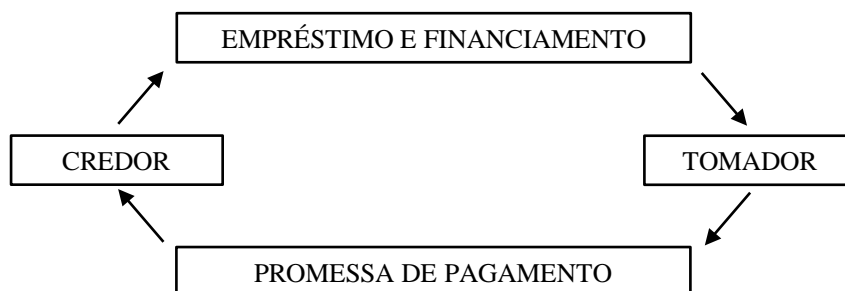


Figura 1 Representação do Crédito
 Fonte: Adaptado de Silva (2008, p. 45)

O crédito tem importante função econômica e social na vida das empresas e das pessoas. Silva (2008) afirma que o papel do crédito é possibilitar que as empresas aumentem seu nível de atividade, estimulem o consumo e o aumento da demanda, facilite às pessoas obterem moradia, bens e até alimentos e financiar a execução de projetos para os quais as empresas não disponham de recursos próprios suficientes. Contudo, cabe ressaltar que o uso inadequado do crédito pode levar uma empresa ou indivíduo à falência (insolvência), assim como também pode vir a ser parte de um processo inflacionário.

Já Schrickel (2000, p. 11), considerando a importante função econômica e social do crédito, esclarece que:

Crédito é um conceito presente no dia-a-dia das pessoas e empresas mais do que possamos imaginar a princípio. Todos nós, tanto as pessoas quanto as empresas, estamos continuamente às voltas com o dilema de uma equação simples: a constante combinação de nossos recursos finitos com o conjunto de nossas imaginações e necessidades infinitas – “existem mais maneiras de se gastar dinheiro, por exemplo, do que de ganhá-lo” – ou seja, a procura por crédito, para satisfazer ao elenco de necessidades, desde as mais elementares de sobrevivência, às mais ousadas e imaginosas.

Na análise de crédito, pode-se optar por duas técnicas distintas: o julgamento humano (análise subjetiva) e os procedimentos estatísticos (análise objetiva). Uma análise bem popular para a análise da capacidade de pagamento dos clientes são as informações fornecidas pelos 5 Cs do Crédito (caráter, capacidade, capital, colateral e condições) (SANTOS, 2012). Na Figura 2, Santos (2012) apresenta os 5 Cs do crédito, os quais podem contribuir para um melhor entendimento desta metodologia.

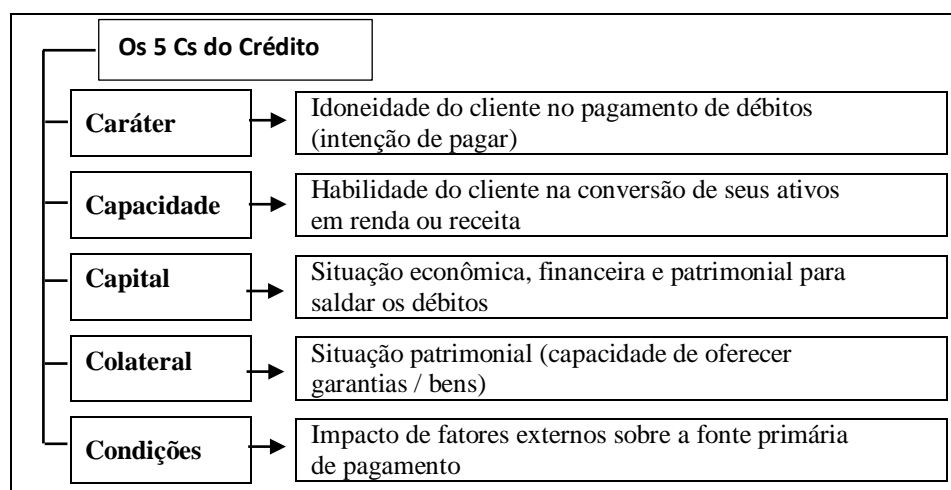


Figura 2 Resumo dos 5 Cs do Crédito
Fonte: Adaptado de Santos (2012, p. 40)

A princípio, qualquer crédito só deve ser concedido após cumprimento da metodologia de aprovação de crédito adotada pela instituição credora. As condições gerais e específicas de cada operação de crédito, empreendidas entre credor e cliente, devem sempre refletir a realidade do mercado e a época de sua efetiva negociação e concessão (SCHRICKEL, 2000).

Kimura et al. (2008, p. 16) observam, ainda, que:

Uma relação de crédito liga o credor ao devedor e estabelece uma obrigação para o devedor efetuar um determinado pagamento ao credor em uma data futura. São exemplos de

operações que envolvem risco de crédito: o mútuo, as debêntures, CDB, RDB etc. Pragmaticamente, qualquer empréstimo de recursos para posterior recebimento implica em um risco de crédito.

Em seu estudo seminal na década de 1920, Knight (2002, p. 224) diferenciou risco de incerteza, definindo-a como “um estado em que não existem bases válidas ou experiência passada para determinar a probabilidade de uma ocorrência específica”. O autor associou o lucro à existência de incerteza.

No que tange à concessão de crédito, a incerteza é inerente a essa atividade e sempre estará presente. Para Sicsú (2010), as instituições financeiras sempre estarão sujeitas a possibilidades de perdas neste tipo de transação. Sendo assim, o recomendável seria quantificar a probabilidade de perda, possibilitando uma melhor classificação dos clientes a empréstimos. Segundo o autor, “à **probabilidade de perda** em uma operação de crédito denominamos **risco de crédito**” (SICSÚ, 2010, p. 1).

Para Silva (2008), as técnicas estatísticas multivariadas têm sido consideradas como ferramentas poderosas na administração do risco de inadimplência existente na concessão de crédito. Para construção de um modelo de previsão de risco de crédito, é importante identificar qual a técnica estatística mais eficiente para modelar os dados da empresa de forma a conseguir a melhor previsão de comportamento dos clientes.

2.2.1 Risco de crédito

Garcia, Guijarro e Moya (2013) e Yu (2014) ressaltam que avaliação do risco de crédito tem sido alvo de uma série de estudos em profundidade nos últimos anos, é o principal foco das áreas financeiras e bancárias em razão, principalmente, da recente crise financeira internacional, que teve um efeito

grave em muitas organizações financeiras. Complementando, Akkoç (2012), Danenas, Garsva e Gudas (2011), Finlay (2011), Oreski e Oreski (2014) e Tsai et al. (2009), frisam que o risco de crédito é uma das questões mais importantes para o setor bancário e tem ganhado cada vez mais atenção nos últimos anos.

Desta forma, Assaf Neto (2010) afirma que o risco é um custo que está sempre presente nos negócios e, portanto, deve ser quantificado. Porém Garcia, Gimenez e Guijarro (2013) elucidam que a gestão do risco de crédito é uma questão chave para qualquer empresa em qualquer momento. Os autores observam, ainda, que existem atualmente várias metodologias que visam prever a probabilidade de inadimplência dos devedores, muitas delas utilizando análise logit ou análise discriminante para classificá-los. Entretanto, novas metodologias fazem uso de redes neurais ou métodos multicritérios.

Harris (2013) e Yu, Wang e Lai (2008) observam que o aumento da concorrência, no setor de serviços financeiros, tem levado muitas empresas a encontrarem formas inovadoras para lidar com o risco, a fim de atingir e/ou manter uma vantagem competitiva. Como resultado do ambiente econômico e de negócio atual, as instituições financeiras enfrentam maior risco de perdas associadas com a inadequação de aprovação de crédito nas decisões. Entretanto, Kou e Wu (2014) afirmam que o principal objetivo da análise de risco de crédito é a de classificar as amostras de clientes em bons ou maus pagadores (solventes ou insolventes).

Segundo Sicsú (2010), quantificar o risco de crédito de forma objetiva, por meio de técnicas quantitativas de análise, tem apresentado grandes vantagens como, por exemplo, rapidez nas decisões, decisões mais consistentes, decisões adequadas e outras.

Complementando, Kimura et al. (2008) afirmam que a gestão de risco, por meio da pesquisa e implementação de modelos quantitativos, tem se tornado uma das principais áreas dentro das empresas modernas.

O risco de crédito, para Santos (2012), compreende a troca de um valor presente por uma promessa de reembolso futuro, não necessariamente certo - risco. Em síntese, quando uma instituição financeira concede crédito, está automaticamente comprando um risco com todas as vantagens e desvantagens envolvidas na transação. Em razão do fato de envolver uma expectativa de retorno do patrimônio que foi cedido, Schrickel (2000) explana que todo crédito está vinculado, de alguma forma, ao risco da perda do valor envolvido.

Segundo Silva (2008, p. 56), “o risco de crédito é a probabilidade de que o recebimento não ocorra, ou seja, é igual a 1 (um), menos a probabilidade de recebimento”. Ainda, segundo o autor, os riscos de crédito de um banco (*bank credit risk*) são instrumentos de grande ajuda para o analista de risco de crédito na redução das perdas decorrentes de erros. Estes podem ser classificados em quatro grupos: risco do cliente ou risco intrínseco (*intrinsic risk*); risco da operação (*transaction risk*); risco de concentração (*concentration risk*); risco da administração do crédito (*credit management risk*).

Schrickel (2000, p. 25-26) afirma que:

O principal objetivo da análise de crédito numa instituição financeira (como para qualquer prestador) é o de identificar os riscos nas situações de empréstimo, evidenciar conclusões quanto à capacidade de pagamento do tomador, e fazer recomendações relativas à melhor estruturação e tipo de empréstimo a conceder, à luz das necessidades financeiras do solicitante, dos riscos, identificando e mantendo, adicionalmente, sob perspectiva, a maximização dos resultados da instituição.

Altman e Sabato (2007) enfatizam que os bancos devem desenvolver modelos de risco de crédito, especificamente, dirigidos ao porte da empresa, a fim de minimizar as suas perdas esperadas e inesperadas. Segundo os autores, muitos bancos e empresas de consultoria já seguem esta prática de separar grandes empresas de pequenas e médias na modelagem de risco de crédito.

Entretanto, a literatura acadêmica carece de um estudo que demonstre os benefícios significativos de tal escolha.

Silva (2008) ressalta que o uso de métodos quantitativos tem sido muito divulgado, o que tem levado muitos bancos a uma corrida em busca dessas técnicas para avaliação do risco de crédito dos clientes devido à sua contribuição para o processo de análise. Entretanto, esses métodos de previsão não podem ser interpretados como ‘receitas milagrosas’ capazes de resolver todos os problemas advindos do risco de crédito contido nas operações.

Saunders (2000) afirma que sistemas de pontuação de crédito podem ser encontrados em praticamente todos os tipos de análise de crédito. A ideia básica é a mesma, isto é, a identificação de fatores que determinem a probabilidade de inadimplência por meio de uma pontuação quantitativa. Essa pontuação, segundo o autor, pode classificar o tomador de crédito potencial em um grupo bom ou ruim.

2.2.2 A análise quantitativa do crédito

Matias (1978, p. 4) salienta que, quando a pauta é a concessão de crédito, a análise financeira tradicional está consagrada no meio empresarial:

[...] a concessão de crédito baseada em informações extraídas das demonstrações financeiras, fornecidas pelas empresas, é o que de usual costuma - fazer. A estrutura de capitais e sua distribuição, bem como as respectivas evoluções anuais, paralelamente a índices financeiros, fluxo de fundos e de caixa, demonstração do capital circulante líquido e do capital de giro próprio, analisa-se giro-margem, além da comparação de indicadores financeiros da empresa, com os de seu ramo de atividade, constituem-se em instrumentos de que se utiliza análise financeira tradicional.

Pereira, Domínguez e Ocejó (2007) afirmam que a evidência empírica permite constatar que vários indicadores que apresentaram bom desempenho de classificação em estudos prévios, também, podem apresentar resultados similares como indicadores explicativos em estudos futuros. Talvez esse seja o fato de vários autores utilizarem a mesma gama de indicadores de forma recorrente, como será demonstrado na metodologia.

No Quadro 1, são apresentados de forma resumida alguns trabalhos desenvolvidos por diversos pesquisadores no campo, tais como Altman (1968) que, segundo Prado et al. (2015, 2016), foi pioneiro no uso das técnicas de análise multivariada em pesquisas sobre falência, além de trabalhos realizados no Brasil, como é o caso da pesquisa de Kanitz (1974) que foi o primeiro trabalho realizado no país. Estes dois estudos foram referência para diversos pesquisadores nos anos que se seguiram. Neste ponto, apenas alguns dos trabalhos que foram encontrados de forma recorrente dentro da revisão realizada para este estudo.

Quadro 1 Síntese dos modelos anteriores de previsão de insolvência

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>O Modelo Altman (1968) de Previsão de Insolvência</i>					
Altman (1968)	AD	66 empresas 33 solventes 33 insolventes	1946 a 1965	95%	Todos os indicadores utilizados, com exceção de X5, apresentaram um nível de significância satisfatório. Entretanto, quando se verificou a contribuição individual de cada indicador para a função discriminante, observou-se que o indicador X3 foi mais importante, seguida pelo X5.
$Z = 0,012X_1 + 0,014X_2 + 0,033X_3 + 0,006X_4 + 0,0999X_5$ $X_1 = (\text{Ativo Circulante} - \text{Passivo Circulante}) / \text{Ativo Total}$ $X_2 = \text{Lucros Retidos} / \text{Ativo Total}$ $X_3 = \text{Lucros Antes dos Juros e Impostos} / \text{Ativo Total}$ $X_4 = \text{Valor de Mercado do Equity} / \text{Exigível Total}$ $X_5 = \text{Vendas} / \text{Ativo Total}$					

“continua”

Quadro 1 “continuação”

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>O Modelo Kanitz (1974) de Previsão de Insolvência</i>					
Kanitz (1974)	AD	Amostra final: 42 empresas 21 solventes 21 insolventes	Empresas insolventes de 1972 a 1974	-	Estudo pioneiro neste tipo de pesquisa no Brasil. Segundo Kanitz (1974, p. 33), foram analisados, aproximadamente, 5.000 demonstrativos financeiros de empresas brasileiras. O autor definiu um fator de insolvência para facilitar a avaliação de empresas e, baseado nele, elaborou um termômetro da insolvência para classificar as empresas que apresentam variações abaixo e acima de ponto de corte. Adiante, ainda, delimitou uma área chamada de penumbra, isto é, uma área que a evidência estatística do fator de insolvência não é suficiente para determinar a situação da empresa.
$FI = 0,05_{x_1} + 1,65_{x_2} + 3,55_{x_3} - 1,06_{x_4} - 0,33_{x_5}$ <p> $X_1 = \text{Lucro Líquido} / \text{Patrimônio Líquido}$ $X_2 = \text{Ativo Circulante} + \text{Realizável a Longo Prazo} / \text{Exigível Total}$ $X_3 = (\text{Ativo Circulante} - \text{Estoques}) / \text{Passivo Circulante}$ $X_4 = \text{Ativo Circulante} / \text{Passivo Circulante}$ $X_5 = \text{Exigível Total} / \text{Patrimônio Líquido}$ </p>					

“continua”

Quadro 1 “continuação”

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>O Modelo Elizabetsky (1976) de Previsão de Insolvência</i>					
Elizabetsky (1976)	AD	110 empresas 82 solventes 28 insolventes	1974	28 indicadores: 100% 15 indicadores: 85% 10 indicadores: 82% 5 indicadores: 69%	Iniciou o trabalho com 60 indicadores, usando um processo de correlação entre alguns grupos de indicadores, com intuito de reduzir a quantidade de indicadores. O autor acabou encontrando um grupo de 28 indicadores, que foram utilizados para a análise discriminante. Adiante, elaborou modelos com 15, 10 e 5 indicadores. Pode-se observar que os indicadores que compõem o modelo com 5 se repetem no modelo com 10 e de 15 indicadores. Isto significa que, à medida que se aumentou a quantidade de indicadores, não foram encontradas novas combinações de indicadores com pesos significantes para excluir algum dos indicadores que estavam no modelo anterior.
$Y = 1,93_{X_{32}} - 0,21_{X_{33}} + 1,02_{X_{35}} + 1,33_{X_{36}} - 1,13_{X_{37}}$ <p> X_{32} = Lucro Líquido / Vendas X_{33} = Disponível / Ativo não Circulante X_{35} = Contas a Receber / Ativo Total X_{36} = Estoques / Ativo Total X_{37} = Passivo Circulante/Ativo Total </p>					

“continua”

Quadro 1 “continuação”

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>O Modelo Matias (1978) de Previsão de Insolvência</i>					
Matias (1978)	AD	100 empresas 50 solventes 50 insolventes	1976 a abril de 1978	89%	<p>Após testar diversos indicadores, o autor encontra uma função discriminante para cálculo do risco que contém informações sobre patrimônio líquido, ativo total, financiamentos bancários, ativo circulante, fornecedores, ativo e liquidez corrente.</p> <p>O autor, ainda, observou que, ao se utilizar 33 indicadores, era possível classificar corretamente 95 empresas da amostra, todavia existiam fases intermediárias com um número menor de indicadores que possuía melhor discriminação, ou seja, o acréscimo de indicadores não melhora muito o modelo.</p>
<p>$Z = 23,792_{x_1} - 8,260_{x_2} - 8,868_{x_3} - 0,764_{x_4} + 0,535_{x_5} + 9,912_{x_6}$</p> <p>$X_1 = \text{Patrimônio Líquido/Ativo Total}$ $X_2 = \text{Financiamentos e Empréstimos Bancários/Ativo Circulante}$ $X_3 = \text{Fornecedores/Ativo Total}$ $X_4 = \text{Ativo Circulante/Passivo Circulante}$ $X_5 = \text{Lucro Operacional/Lucro Bruto}$ $X_6 = \text{Disponível/Ativo Total}$</p>					

“continua”

Quadro 1 “continuação”

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>O Modelo Altman, Baidya e Dias (1979) de Previsão de Insolvência</i>					
Altman, Baidya e Dias (1979)	AD	58 empresas 35 solventes 23 insolventes	1975 a 1977	88%	Os autores adaptaram o modelo original de Altman (1968) para o contexto brasileiro. Todos os cinco indicadores utilizados apresentaram nível de significância de 1%. Entretanto, os resultados dos dois modelos encontrados são, essencialmente, idênticos no que diz respeito à precisão de classificação, exceto por uma ligeira superioridade do modelo Z_1 .
$Z_1 = -1,44 + 4,03_{x_2} + 2,25_{x_3} + 0,14_{x_4} + 0,42_{x_5}$ $Z_2 = -1,84 - 0,51_{x_1} + 6,32_{x_3} + 0,71_{x_4} + 0,53_{x_5}$ $X_1 = (\text{Ativo Circulante} - \text{Passivo Circulante}) / \text{Ativo Total}$ $X_2 = (\text{Não Exigível} - \text{Capital Aportado pelos Acionistas}) / \text{Ativo Total}$ $X_3 = (\text{Lucros Antes de Juros e de Impostos}) / \text{Ativo Total}$ $X_4 = \text{Patrimônio Líquido} / \text{Exigível Total}$ $X_5 = \text{Vendas} / \text{Ativo Total}$					

“continua”

Quadro 1 “continuação”

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>O Modelo de Silva (1982) de Previsão de Insolvência</i>					
Silva (1982)	AD	419 empresas 259 solventes 160 insolventes	-	31 indicadores: 94% 13 indicadores: 91% 6 indicadores: 87%	Foram trabalhados 85 indicadores, para obter as melhores composições para modelos com seis indicadores. Adiante, foram criados dois modelos: um para empresas comerciais ($Z1_c$) e outro para empresas industriais ($Z1_i$). Além de adaptá-los para analisar um ano antes do evento e para dois anos antes do evento de falência.
$Z1_i = 0,722 - 5,124_{E23} + 11,016_{L19} - 0,342_{L21} - 0,048_{L26} + 8,605_{R13} - 0,004_{R29}$ $Z1_c = -1,327 + 7,561_{E5} + 8,201_{E11} - 8,546_{L17} + 4,218_{R13} + 1,982_{R23} + 0,091_{R28}$ <p> E_{23} = Duplicatas Descontadas / Duplicatas a Receber L_{19} = Estoques / Custo do Produto Vendido L_{21} = Fornecedores / Vendas L_{26} = (Estoques Médio/Custo do Produto Vendido) x 360 R_{13} = (Lucro Operacional + Despesas Financeiras)/(Ativo Médio – Investimentos Médio) R_{29} = $\frac{\text{Passivo Circulante} + \text{Exigível a Longo Prazo}}{\text{Lucro Líquido} + 0,1 (\text{Imobilizado Médio} - \text{Resultado de Correção Monetária})}$ E_5 = (Reservas + Lucros Suspensos) / Ativo Total E_{11} = Disponível / Ativo Total L_{17} = $\frac{\text{Ativo Circulante} - \text{Disponível} - \text{Passivo Circulante} + \text{Financiamentos} + \text{Duplicatas Descontadas}}{\text{Vendas}}$ R_{23} = Lucro Operacional / Lucro Bruto R_{28} = $\frac{\text{Patrimônio Líquido}}{\text{Passivo Circulante} + \text{Passivo não Circulante}} / \frac{\text{Lucro Bruto}}{\text{Vendas}} \times 100$ $\text{PMRE} + \text{PMRV} - \text{PMPC}$ </p>					

“continua”

Quadro 1 “continuação”

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>O Modelo Castro Junior (2003) de Previsão de Insolvência</i>					
Castro Junior (2003)	AD, RL e RNA	40 empresas 20 solventes 20 insolventes	1996 e 2002	AD 70% RL 81,25% a 87,5% RN 90% a 95%	Utilizou 16 indicadores para análise, empregando um critério para escolha dos indicadores fundamentado nos melhores subconjuntos possíveis. Alguns dos indicadores utilizados foram pouco significativos no que diz respeito à sua capacidade de classificação. Ao todo foram gerados 7 modelos. Os resultados demonstraram a superioridade das redes neurais artificiais sobre a Regressão Logística e a Análise Discriminante Linear.
<p>Dos 3 indicadores de estrutura de capital, apenas o indicador EE_3, composição do endividamento, foi significativa. Fazendo parte de 5 dos 7 modelos apresentados. $EE_3 = \text{Passivo Circulante} / \text{Capitais de Terceiros}$.</p>					
<p>Dos 3 indicadores de liquidez, o indicador L_5, liquidez corrente, foi significativo, fazendo parte de 4 dos 7 modelos apresentados. Outro indicador importante nos modelos foi a raiz do indicador L_6, liquidez seca a qual fez parte de dois modelos (logísticos e de duas redes neurais). $L_5 = \text{Ativo Circulante} / \text{Passivo Circulante}$; $L_6 = \text{Disponíveis} / \text{Passivo Circulante}$.</p>					
<p>Dentre os 6 indicadores de rentabilidade, três foram importantes em duas das três redes neurais desenvolvidas. Foram eles os indicadores R_7, giro do ativo, R_9, retorno sobre o ativo, e R_{12}, lucros retidos sobre o ativo. $R_7 = \text{Vendas Líquidas} / \text{Ativo Total}$; $R_9 = \text{Lucro Líquido} / \text{Ativo Total}$; $R_{12} = \text{Lucros Retidos} / \text{Ativo Total}$.</p>					
<p>O único grupo em que todos os seus indicadores fizeram parte de pelo menos um dos modelos foi o dos indicadores de atividade. Dos 4 indicadores do grupo, o indicador AR_{14}, recebimento de vendas, foi o que esteve presente em mais modelos: três. O outro indicador deste grupo que merece destaque é a AR_{16}, estoque sobre venda, que foi utilizada em duas redes neurais. $AR_{13} = \text{Estoques} / \text{Custo de Mercadorias Vendidas}$; $AR_{14} = \text{Duplicatas a Receber} / \text{Vendas Líquidas}$; $AR_{15} = \text{Contas Fornecedores} / \text{Compras}$; $AR_{16} = \text{Valor em Estoques} / \text{Vendas Líquidas}$.</p>					

“continua”

Quadro 1 “conclusão”

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>O Modelo Brito, Assaf Neto e Corrar (2009) de Previsão de Insolvência</i>					
Brito, Assaf Neto e Corrar (2009)	RL	66 empresas 33 solventes 33 insolventes	1995 a 2006	89%	Primeiramente o trabalho faz uma atualização do modelo de risco de crédito proposto por Brito e Assaf Neto (2008), em seguida, utiliza para análise do default a técnica de conglomerados, criando uma classificação de oito classes de risco, sendo sete contemplando empresas solventes e uma contemplando empresas insolventes.
$h(p / 1 - p) = - 4,03 - 3,70 VL_{12} + 11,66 E_{16} - 7,86 AD_{19} - 11,33 AD_{22}$ <p> $VL_{12} = (\text{Lucros Acumulados} + \text{Reserva de Lucros}) / \text{Ativo total}$ $E_{16} = (\text{Passivo circulante financeiro} + \text{Exigível a longo prazo financeiro}) / \text{Ativo Total}$ $AD_{19} = (\text{Ativo circulante} - \text{Passivo circulante}) / \text{Ativo Total}$ $AD_{22} = (\text{Ativo circulante financeiro} - \text{Passivo circulante financeiro}) / \text{Vendas líquidas}$ </p>					

(*) AD = Análise Discriminante; RL = Regressão Logística; RNA = Redes Neurais Artificiais

Fonte: Elaborado pelo autor com base nas pesquisas citadas no próprio quadro

Segundo Kanitz (1978, p. 2), “a primeira indagação é: de que vale uma análise profunda do balanço, se não for capaz de revelar os sintomas de uma insolvência iminente?”. O autor afirma que a insolvência é um processo que tem começo, meio e fim, visto que “os primeiros sintomas de uma insolvência surgem muito antes que ela se concretize”. Por isto, antes da falência, deve haver nos balanços da empresa alguns indícios do que está por vir, contudo é preciso localizá-los.

2.3 O Modelo Fleuriet

Brasil e Brasil (2008) salientam que, tradicionalmente, a análise financeira parte de uma visão estática da organização, baseada na solvência da empresa (via 1, FIGURA 3), em um sistema que parou de funcionar. Já, na perspectiva do Modelo Fleuriet (enfoque dinâmico) de análise financeira, voltado para a liquidez empresarial (via 2, FIGURA 3), parte-se do princípio de que a empresa é um organismo vivo, o que possibilita responder se ela tem capacidade de cumprir com suas obrigações, mantendo-se em funcionamento e permitindo ao gestor tomar medidas durante o processo.

Estas duas visões e sua respectiva complementariedade (integração) são desejadas, como sugerem Brasil e Brasil (2008). Esta necessidade de integração entre os dois modelos pode ser visualizada na Figura 3.

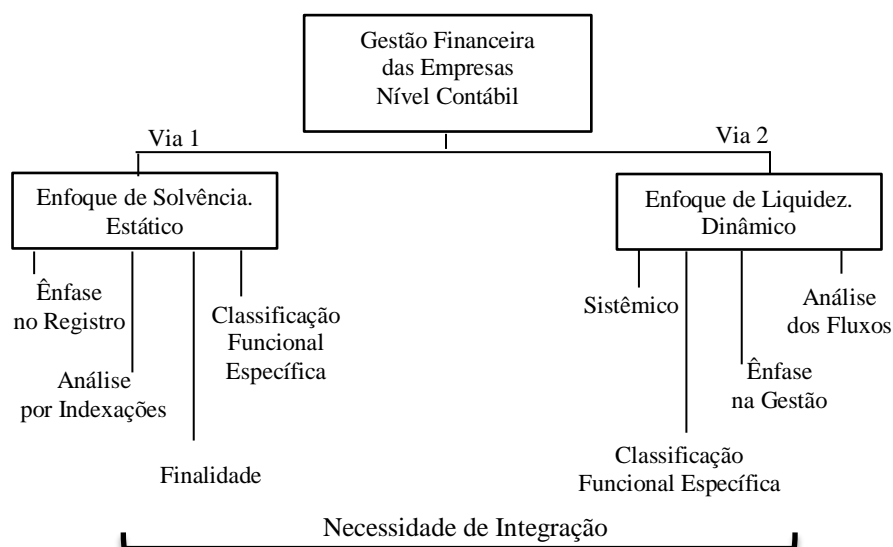


Figura 3 Necessidade de Integração do Modelo Tradicional e do Modelo Fleuriet
 Fonte: Adaptado de Brasil e Brasil (2008, p. 3)

Entretanto, quanto à previsão de insolvência, a literatura financeira não estabelece de forma definitiva quais são os melhores indicadores a serem utilizados. Vários indicadores são utilizados de forma recorrente por vários pesquisadores, contudo o processo de escolha depende, normalmente, da disponibilidade de dados e da intuição do pesquisador.

Segundo Assaf Neto (2010), o Modelo Tradicional de análise das demonstrações financeiras constitui um dos mais importantes estudos da administração financeira. Uma melhor compreensão desta metodologia pode ser alcançada, por meio dos indicadores econômico-financeiros, classificados em quatro grupos: liquidez e atividade, endividamento e estrutura, rentabilidade e análise de ações.

A esse respeito, Fleuriet et al. (2003) argumentam que a estrutura da apresentação tradicional, que agrupa diversas contas do ativo e do passivo de forma horizontal e, de acordo com os prazos destas contas, numa ordem de disponibilidade decrescente, é errônea. Os autores frisam que as contas do ativo

e do passivo devem ser consideradas em relação à realidade dinâmica das empresas e classificadas, de acordo com o seu ciclo, ou seja, o tempo que leva para se realizar uma rotação.

2.3.1 O Balanço Patrimonial no Modelo Fleuriet

Padoveze e Benedicto (2010) frisam que a Lei nº 6.404/76 (BRASIL, 1976), a lei das sociedades anônimas e que apresenta a estrutura básica das demonstrações financeiras no Brasil, sofreu inúmeras atualizações, providas pela Lei nº 11.638/07, de 28 de dezembro de 2007 e Lei nº 11.941, de 27 de maio de 2009 (BRASIL, 2007, 2009). Sobre essa estrutura básica de apresentação das demonstrações financeiras, o Modelo proposto por Fleuriet et al. (1978) sugere uma reclassificação para um padrão completamente dinâmico e funcional, com o objetivo de atender a administração financeira da organização de forma satisfatória.

De acordo com Fleuriet et al. (2003, p. 7):

Para uma melhor compreensão do modelo de análise financeira que se pretende definir, as contas do ativo e do passivo devem ser consideradas em relação à realidade dinâmica das empresas, em que as contas são classificadas de acordo com o seu ciclo, ou seja, o tempo que leva para se realizar uma rotação.

Fleuriet et al. (2003) apresentam como ocorre a classificação das contas dentro do Balanço Patrimonial, de acordo com o novo modelo proposto. Um exemplo dessa metodologia pode ser visualizada no Quadro 2.

Quadro 2 Os ciclos no Balanço Patrimonial

ATIVO		PASSIVO	
ATIVO CIRCULANTE	CONTAS ERRÁTICAS	<u>Circulante</u> Financeiro Numerário em Caixa, Bancos conta movimentos, Títulos e Valores Mobiliários.	CONTAS ERRÁTICAS Financeiro CONTAS CÍCLICAS Operacional CONTAS NÃO CÍCLICAS Permanente
	CONTAS CÍCLICAS	Operacional Duplicatas a receber, Estoques de Produtos Acabados, Estoque de Produção em andamento Estoque de Matérias-Primas, Adiantamento a fornecedores etc.	
ATIVO NÃO CIRCULANTE	CONTAS NÃO CÍCLICAS	<u>Ativo não Circulante*</u> Permanente Empréstimos a Terceiros Títulos a receber etc. Investimentos, Imobilizados	PASSIVO CIRCULANTE CONTAS CÍCLICAS CONTAS NÃO CÍCLICAS Permanente PASSIVO NÃO CIRCULANTE
		Duplicatas Descontadas, Empréstimos Bancários em Curto Prazo, Dividendos a Pagar, Imposto de Renda a recolher etc.	
		Fornecedores de Matérias-Primas, Salários e Encargos Sociais, Impostos e Taxas.	
		<u>Passivo não Circulante*</u> Exigível em Longo Prazo, Empréstimos Bancários, Debêntures, Financiamentos etc.	
		Patrimônio Líquido Capital Social Reservas, Lucros ou prejuízos acumulados.	

* Atualizado segundo atualizações providas pela Lei nº 11.638/07 (BRASIL, 2007)

Fonte: Adaptado de Fleuriet et al. (2003, p. 8)

Segundo Fleuriet et al. (2003) e Vieira (2008), algumas contas apresentam um movimento mais lento, quando analisadas isoladamente, em relação a outras contas do Balanço Patrimonial, podendo ser chamadas de não cíclicas ou permanentes (Fixas). Outras contas são diretamente influenciadas pelo volume de negócios (produção e vendas) e por características do ciclo operacional (condições de recebimento e pagamento, prazo de estocagem), podendo ser classificadas como cíclicas ou operacionais, por estarem relacionadas com o ciclo operacional do negócio (ASSAF NETO; SILVA, 2012; FLEURIET et al., 2003).

E, por fim, como defendem Fleuriet et al. (1978), existem contas que não apresentam necessariamente um vínculo direto com o ciclo operacional da empresa, variando em função da conjuntura e do risco de maior ou menor liquidez que a empresa deseja assumir, apresentando um movimento ‘descontínuo e errático’. Elas são chamadas de erráticas ou financeiras. Segundo Fleuriet et al. (2003, p. 7): “Errático, do latim *erraticu*. Errante, vadio, erradio, aleatório, andando fora do caminho. Ou seja, implica a não ligação dessas contas ao Ciclo Operacional da empresa”.

Padoveze e Benedicto (2010, p. 264) elucidam que:

Como consequência desse conceito, as contas cíclicas, sejam ativas ou passivas, não devem fazer parte da liquidez. A liquidez da empresa é exclusivamente decorrente do seu saldo de tesouraria, que é representado pelas contas erráticas. Esta é uma conclusão fundamental e de extrema importância.

Ainda, segundo os autores, começa-se a compreender a capacidade de pagamento da empresa sob uma perspectiva mais profunda e realística, não enviesando os fundamentos da liquidez e da necessidade de investimentos no giro (PADOVEZE; BENEDICTO, 2010).

2.3.2 Os principais indicadores que compõem o modelo

Araújo, Costa e Camargos (2013) enfatizam que o Modelo Fleuriet foi criado para estabelecer uma nova metodologia de avaliação financeira. Sendo, principalmente, focado na análise financeira ou, ainda, no capital de giro, o Modelo Fleuriet possibilita uma visualização sistemática da empresa, por meio de um ponto de vista financeiro de liquidez, demonstrando o impacto das diversas áreas da gestão empresarial assim como suas interdependências.

Dessa nova segmentação do Balanço Patrimonial, surgem os indicadores do Modelo Fleuriet, que são: Necessidade de Capital de Giro (NCG), Capital de Giro (CDG) e Saldo de Tesouraria (T). Estes novos indicadores são utilizados na análise econômico-financeira das empresas não mais de forma estática, mas, sim, compreendendo a organização como um ‘organismo vivo’ (ASSAF NETO, 2012; ASSAF NETO; SILVA, 2012; BRAGA, 1991; BRASIL; BRASIL, 2008; CARVALHO, 2004; FLEURIET et al., 1978; MELO; COUTINHO, 2007; OLINQUEVITCH; SANTI FILHO, 2009; PADOVEZE; BENEDICTO, 2010; SANVICENTE; MINARDI, 1998; SILVA, 2012; VIEIRA, 2008).

Considerando os três indicadores, é possível realizar a análise do Efeito Tesoura, o Termômetro da Liquidez, que resulta da relação entre Saldo de Tesouraria e Necessidade de Capital de Giro (T/NCG) e, ainda, avaliar os tipos de estrutura financeira. O próximo tópico traz um maior detalhamento sobre os indicadores e suas análises.

2.3.2.1 Necessidade de Capital de Giro (NCG)

Fleuriet et al. (2003) descrevem a Necessidade de Capital de Giro (NCG) da seguinte maneira: dentro do ciclo financeiro das empresas, as saídas

de caixa (gastos com a produção) ocorrem antes das entradas de caixa (recebimento das vendas). As operações da empresa, então, criam uma necessidade de aplicação permanente de fundos (denominada necessidade de capital de giro), que é evidenciada, no Balanço Patrimonial, por uma diferença positiva entre o valor das contas operacionais/cíclicas do ativo (Ativo Operacional – AO) e das contas operacionais/cíclicas do passivo (Passivo Operacional – PO).

$$NCG = AO - PO \quad (01)$$

Melo e Coutinho (2007) esclarecem que o Modelo Fleuriet pode ser utilizado como indicador conjunto de solvência e rentabilidade. Os autores afirmam que, para a NCG, os especialistas esperam, normalmente, baixos valores como sinal positivo para empresa, isto é, quanto mais elevado o valor desse indicador, maior será a probabilidade da empresa ter de utilizar de recursos financeiros de curto prazo para financiá-lo e eles não apresentam garantia alguma de renovação, aumentando, assim, o risco de insolvência da empresa.

2.3.2.2 Capital de Giro (CDG)

Denomina-se Capital de Giro (CDG) a diferença entre o passivo não circulante e o ativo não circulante. O Ativo não Circulante (ANC) é formado por contas não cíclicas do ativo e o Passivo Não Circulante (PNC) são as contas não cíclicas do passivo. Segundo Vieira (2008), o capital de giro representa uma fonte de recursos de longo prazo que pode ser utilizado para financiar as necessidades de capital de giro da empresa.

Entretanto, se negativo, o capital de giro representa uma escassez de recursos de longo prazo, forçando a empresa a financiar suas atividades com recursos de curto prazo. O cálculo do Capital de giro pode ser realizado pela fórmula a seguir:

$$CDG = PNC - ANC \quad (02)$$

Fleuriet et al. (2003, p. 11) esclarecem que:

A Necessidade de Capital de Giro, quando positiva, reflete uma aplicação permanente de fundos que, normalmente, deve ser financiada com os fundos permanentes utilizados pela empresa. Quando a NCG é financiada com recursos de curto prazo, geralmente empréstimos bancários, o risco de insolvência aumenta.

Melo e Coutinho (2007) mencionam que, do ponto de vista da análise de solvência, os especialistas esperam como indicativos favoráveis para a empresa altos valores para CDG. Por ser uma fonte de recursos de longo prazo, o CDG, quando suficientemente alto, ou seja, maior que a Necessidade de Capital de Giro, traz tranquilidade quanto à renovação dos prazos de financiamento de curto prazo de fontes externas.

Olinquevitch e Santi Filho (2009), ainda, consideram que o CDG pode ser tratado pela ótica dos financiamentos da NCG e, nesse sentido, pode-se financiar as NCG de três formas: com recursos próprios, com recursos de terceiros de longo prazo e/ou com recursos de terceiros de curto prazo.

2.3.2.3 Saldo de Tesouraria (T)

Silva (2012) esclarece que o Saldo de Tesouraria (T) é compreendido pelos itens de caráter financeiro como empréstimos de curto prazo, aplicações financeiras e disponibilidades, por exemplo. O saldo de tesouraria pode assumir valores maiores ou menores do que zero, contudo, quando o valor for menor que zero, significa que a empresa tem débitos de curto prazo, junto a instituições financeiras ou, ainda, outras dívidas de curto prazo que não estão relacionadas ao ciclo operacional e, ainda, superiores a seus recursos de curto prazo.

Araújo, Costa e Camargos (2013) afirmam que o saldo de tesouraria é mensurado a partir do confronto entre as contas do ativo financeiro (AF) e as contas do passivo financeiro (PF), podendo ser, também, obtido pela diferença entre o CDG e a NCG.

$$T = AF - PF$$

ou

(03)

$$T = CDG - NCG$$

Melo e Coutinho (2007) explanam que, tendo em vista a análise da solvência empresarial, o saldo de tesouraria pode ser interpretado por analistas como indicativo favorável para empresa quando apresentar valores mais elevados ou positivos. Isso porque quanto menor (ou negativo) ele for, de mais recursos financeiros de curto prazo a empresa precisará para financiar suas atividades, aumentando o risco de insolvência e estes recursos não apresentam garantia de renovação.

2.3.2.4 Efeito Tesoura (*Overtrading*)

Sanvicente e Minardi (1998) observam que o Efeito Tesoura é um fator relevante para prever falências no Brasil. Seguindo esta mesma linha, Carvalho (2004) afirma que, quando uma empresa apresenta, por vários exercícios seguidos, um crescimento das Necessidades de Capital de Giro (NCG), superior ao do seu Capital de Giro (CDG), pode-se dizer que ela convive com o denominado Efeito Tesoura, que será identificado por um crescente Saldo em Tesouraria (T) negativo, conforme Figura 4.

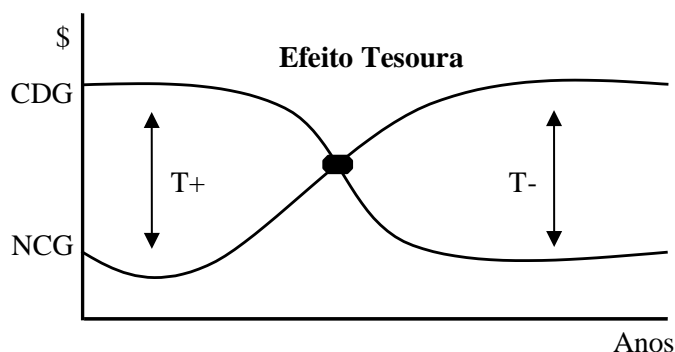


Figura 4 Representação gráfica do Efeito Tesoura

Fonte: Adaptado de Assaf Neto (2012, p. 206) e Carvalho (2004, p. 65)

Brasil e Brasil (2008), ainda, dentro desta mesma corrente teórica, afirmam que a patologia da administração do Saldo em Tesouraria é o Efeito Tesoura, que surge de uma excessiva dependência de empréstimos de curto prazo, o que torna crítica a liquidez da empresa. Os autores frisam que qualquer corte de crédito que ocorra por efeito de desaquecimento da economia e, portanto, das vendas, pode levar a empresa a um estado de insolvência rapidamente, pois o atraso com os fornecedores é inevitável nestas condições.

2.3.2.5 Termômetro de Liquidez (TL)

Outro indicador que pode ser analisado no Modelo Fleuriet é o Termômetro da Situação Financeira (TSF), mais popularmente chamado de Termômetro de Liquidez (TL). Para Fleuriet et al. (2003), o termômetro de liquidez demonstra a magnitude do saldo negativo de tesouraria em relação à NCG e sua tendência ao longo do tempo e, dependendo dos sinais dos dois indicadores envolvidos, apresenta a participação do capital de terceiros de curto prazo que financiam a NCG.

Como os indicadores chaves do termômetro podem vir a assumir valores tanto negativos como positivos, Vieira (2008) explica que esta medida de liquidez deve ser calculada, considerando o valor algébrico do Saldo em Tesouraria (T) em relação ao módulo da NCG. O autor, ainda, observa que quanto mais negativo for o valor apresentado pelo indicador, maior será a utilização de recursos de curto prazo oriundos de instituições financeiras, sendo assim, pior tenderá a ser a situação financeira da empresa.

$$TL = \frac{T}{|NCG|} \quad (04)$$

Vieira (2008) frisa que a NCG é uma demanda de recursos de natureza operacional que, pelo seu forte vínculo com as operações, assume caráter de permanência ou longo prazo. Por essa característica, sua fonte de financiamento deve possuir natureza semelhante provinda de forma preponderante das fontes de longo prazo.

2.3.2.6 Tipos de estrutura financeira

Marques e Braga (1995) compreendem que a afinidade entre o saldo de tesouraria (T), necessidade de capital de giro (NCG) e o capital de giro (CDG) permitem identificar seis estruturas específicas de financiamento. Cabe observar que, no trabalho inicial proposto por Fleuriet et al. (1978), foram considerados apenas quatro tipos de estruturas financeiras: I, II, III e IV (FLEURIET et al., 2003). Neste estudo, como pode ser visto na Tabela 1, os autores desconsideraram condições em que o T, NCG e CDG fossem iguais a zero.

Tabela 1 Tipos de estrutura e situação financeira

Tipo	CDG	NCG	T	Situação
I	+	-	+	Excelente
II	+	+	+	Sólida
III	+	+	-	Insatisfatória
IV	-	+	-	Péssima
V	-	-	-	Muito ruim
VI	-	-	+	Alto risco

Fonte: Adaptado de Marques e Braga (1995, p. 56)

Brasil e Brasil (2008, p. 31) explicam que “essas três variáveis NCG, CDG e T permitem definir o perfil conjuntural e estrutural das empresas, vinculado, respectivamente, à política financeira adotada (nível de risco) e ao negócio”.

Fleuriet et al. (2003) observam que as empresas do Tipo I, embora apareçam com menor frequência, merecem ser avaliadas, pois possuem uma posição financeira excelente no que diz respeito ao seu alto nível de liquidez. Complementando, Marques e Braga (1995) demonstram que a NCG negativa representa que o PO é superior ao AO, isto é, os itens do ativo cíclico

apresentam elevado grau de rotação e um ciclo financeiro reduzido. Mesmo que o CDG seja superior ao montante da NCG, o CDG, ainda, é inferior ao T, o que significa a existência de um AF bem mais significativo que o PF.

O Tipo II evidencia uma situação financeira sólida, visto que dispõe de um T positivo que lhe permite enfrentar aumentos temporários da NCG, como mencionado por Fleuriet et al. (2003). Marques e Braga (1995) frisam que essa posição é a mais encontrada no meio empresarial. O fato dos três indicadores serem positivos possibilita que no máximo o T iguale-se a NCG, mas que sempre seja inferior ao CDG. Sendo assim, os recursos de longo prazo investidos no CDG assegurarão a continuidade do T positivo (favorável), desde que o nível de atividade operacional seja mantido. Marques e Braga (1995), ainda, enfatizam que caso ocorram alterações nesse nível de atividade (sazonalidade ou recessão, por exemplo), podem surgir desequilíbrios financeiros.

Fleuriet et al. (2003, p. 16) enfatizam que, no Tipo III, a NCG é maior do que o CDG e, por isso, o saldo de Tesouraria é negativo. A empresa financia parte de sua NCG com créditos de curto prazo. Esse estado não é grave quando a NCG apresenta-se, temporariamente, elevada. Entretanto, segundo Fleuriet et al. (2003), a liquidez da empresa estará ameaçada (estando a NCG em seu nível normal) se seus créditos a curto prazo não forem renovados.

Essa conjuntura pode vir a se agravar na presença de uma recessão, ocasião em que alguns itens do ativo operacional encontrarão dificuldades de efetivação acarretando no aumento do ciclo financeiro, ao passo que o passivo financeiro tende a se elevar em função das taxas de juros significativas (MARQUES; BRAGA, 1995).

De acordo com Fleuriet et al. (2003, p. 16), o Tipo IV “configura uma estrutura financeira típica de empresa que luta por sua sobrevivência”. De fato, a empresa apresenta elevado risco de falência, pois financia suas aplicações

permanentes com fundos de curto prazo que podem não ser renovados. Marques e Braga (1995) evidenciam que, na estrutura do Tipo V, a condição financeira apresenta-se como muito ruim. Além do CDG negativo, o que sugere que fontes de curto prazo são utilizadas para financiar ativos de longo prazo, o valor da NCG, também negativo, sendo seu valor superior ao do CDG.

Por último, Marques e Braga (1995) comentam que, na situação de alto risco originária da utilização da estrutura do Tipo VI, continuam negativos o CDG e a NCG. Entretanto, a NCG é inferior ao CDG. Essa conjuntura possibilita que o T seja positivo, o que pode indicar que a empresa não está realizando suas operações de maneira adequada, ainda que esteja aplicando recursos de curto prazo (AF) com eficiência no mercado financeiro.

2.3.3 Análise de crédito e o Modelo Fleuriet

Fleuriet et al. (2003, p. 75) afirmam que o principal objetivo da análise de crédito é estimar quais são as chances da empresa reembolsar sua dívida na data do vencimento. Para isso, o autor explana que “a mais simples análise de crédito é aquela que consiste em se calcular os indicadores de liquidez da empresa para estudar a evolução de sua liquidez no curso dos últimos exercícios [...] comparar a liquidez da empresa com a de outras sociedades do mesmo setor”.

A respeito dos indicadores de liquidez - liquidez imediata, liquidez seca e liquidez corrente - Fleuriet et al. (2003) afirmam que as “três categorias de indicadores de liquidez apresentam um inconveniente maior: elas não fornecem nenhuma indicação sobre a situação de liquidez da empresa porque, no exigível em curto prazo, não se distingue o que é financiamento renovável e financiamento excepcional”.

Padoveze e Benedicto (2010, p. 262, grifo nosso) elucidam que:

Considerando as naturezas diferenciadas das contas do giro, há uma reclassificação do capital circulante: as contas cíclicas são classificadas como giro e, conseqüentemente, o total dos ativos cíclicos menos o total dos passivos cíclicos indica a *necessidade líquida de capital de giro* (NLCG). As demais contas, de caráter financeiro e não vinculadas às operações, são denominadas ***contas de tesouraria, e só com elas é que se deveria calcular a liquidez empresarial e a capacidade de solvência da empresa no curto prazo.***

Tendo em vista o exposto por Padoveze e Benedicto (2010) sobre a metodologia desenvolvida por Fleuriet em 1978, alguns estudos sobre a liquidez, solvência e/ou crédito, utilizando o Modelo Fleuriet, podem ser encontrados na literatura. Neste sentido, apresenta-se, no Quadro 3, um breve resumo de pesquisadores que desenvolveram estudos dentro dessa temática, tais como Carvalho (2004), Eifert (2003), Minussi, Damacena e Ness Junior (2002) e Sanvicente e Minardi (1998).

Quadro 3 Síntese de trabalhos que utilizaram o Modelo Fleuriet

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>Indicadores do Modelo Fleuriet utilizadas por Sanvicente e Minardi (1998) na Previsão de Insolvência</i>					
Sanvicente e Minardi (1998)	AD	Amostra total 81 empresas 44 solventes 37 insolventes	1986 a 1997	Melhor previsão: 81,8%	Primeiro trabalho a testar a dinâmica do <i>overtrading</i> na análise do risco de crédito no Brasil. Ao todo foram testados 14 indicadores independentes. Entretanto, segundo os autores, os indicadores contábeis que apresentaram maior poder de previsão de concordatas foram os indicadores de liquidez, não sendo possível obter melhores resultados ao substituir o índice de liquidez pelos indicadores referentes à dinâmica do <i>overtrading</i> (necessidade de capital de giro e saldo de tesouraria).
$\frac{NCG}{AT} = \frac{\text{Ativo Circulante Operacional} - \text{Passivo Circulante Operacional}}{\text{Ativo Total}}$ $\frac{T}{AT} = \frac{\text{Ativo Circulante Financeiro} - \text{Passivo Circulante Financeiro}}{\text{Ativo Total}}$					

“continua”

Quadro 3 “continuação”

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>Indicadores do Modelo Fleuriet utilizadas por Minussi, Damacena e Ness Junior (2002) na Previsão de Insolvência</i>					
Minussi, Damacena e Ness Junior (2002)	RL	323 empresas 168 solventes 155 insolventes	1998 a 2000	95%	Foram selecionados 49 indicadores financeiros, para a análise de solvência, sendo 45 pertencentes ao Modelo Tradicional de análise financeira e 4 pertencentes ao Modelo Fleuriet. Dos cinco indicadores significativos para o modelo final, dois são referentes ao Modelo Fleuriet de análise financeira.
$\frac{T}{VL} = \frac{\text{Ativo Circulante Financeiro} - \text{Passivo Circulante Financeiro}}{\text{Venda Líquida}}$ $\frac{NCG}{VL} = \frac{\text{Ativo Circulante Operacional} - \text{Passivo Circulante Operacional}}{\text{Venda Líquida}}$					

“continua”

Quadro 3 “continuação”

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>Indicadores do Modelo Fleuriet utilizadas por Eifert (2003) na Previsão de Insolvência</i>					
Eifert (2003)	AD e RL	51 empresas 30 solventes 21 insolventes	1996 e 1997	Melhores modelos: AD 92,7% RL 100%	Testaram-se 174 indicadores, sendo compostos por 64 referentes ao último demonstrativo (período t), 55 referentes ao penúltimo demonstrativo (período t-1) e 55 referentes ao antepenúltimo demonstrativo (período t-2). Com os grupos de indicadores (t), (t e t-1) e (t, t-1 e t-2), utilizou-se do método <i>stepwise</i> tanto para AD quanto para RL para gerar 6 modelos. Segundo o autor, percebe-se claramente a superioridade da RL sobre a AD em todos os aspectos.
$\frac{T}{ROL} = \frac{\text{Saldo de Tesouraria}}{\text{Receita Operacional Líquida}}$ $\frac{PL-AP}{NCG_{t-2}} = \frac{\text{Patrimônio Líquido} - \text{Ativo Permanente}}{\text{Necessidade de Capital de Giro}}$ $\frac{PCF}{AC} = \frac{\text{Passivo Circulante Financeiro}}{\text{Ativo Circulante}}$					

“continua”

Quadro 1 “conclusão”

Autores / Ano	Modelo	Dimensão Amostra	Período	Acurácia (%)	Conclusão/Observações
<i>Indicadores do Modelo Fleuriet utilizadas por Carvalho (2004) na Previsão de Insolvência</i>					
Carvalho (2004)	AD	100 empresas 50 solventes 50 insolventes	2000 a 2002	Melhor modelo 96%	Desenvolveu cinco modelos de previsão de insolvência. O autor afirma que, na elaboração de seu estudo, pode-se destacar a importância da dinâmica do <i>overtrading</i> como sendo de grande valia na construção de um modelo de previsão de insolvência para empresas comerciais.
$\frac{NCG}{AT} = \frac{\text{Necessidade de Capital de Giro}}{\text{Ativo Total}}$ $\frac{T}{AT} = \frac{\text{Saldo de Tesouraria}}{\text{Ativo Total}}$					

(*) AD = Análise Discriminante; RL = Regressão Logística; RNA = Redes Neurais Artificiais
 Fonte: Elaborado pelo autor com base nas pesquisas citadas no próprio quadro

Como se pode observar no Quadro 3, poucos são os estudos que abordam o Modelo Fleuriet para avaliação da solvência empresarial. Nestes, os indicadores com maior destaque são: saldo de tesouraria e a necessidade de capital de giro. No próximo tópico, são apresentadas as técnicas de análise para criação dos modelos propostos.

2.4 Técnicas para análise de crédito

Após a coleta dos dados amostrais (empresas solventes e insolventes), inicia-se à criação dos modelos e, com base nesta criação, realizam-se as suas respectivas análises e comparações. Para o presente estudo, são utilizados os modelos de análise discriminante, regressão logística e redes neurais, que são exemplificados nos tópicos a seguir.

2.4.1 Análise discriminante - AD

O primeiro estudo na temática de previsão de falência, utilizando análise discriminante, é o de Altman (1968) intitulado *Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy*. Baseados nesta obra seminal, vários outros pesquisadores fizeram uso da análise discriminante para avaliação do risco de crédito e previsão de solvência.

Em sua revisão de literatura, Dimitras, Zanakis e Zopounidis (1996) destacam o interesse na década de 1990 por pesquisas sobre previsão de falências de empresas e o grande número de artigos sobre este tema. Segundo os autores, a análise discriminante aparece como técnica mais utilizada (pesquisa realizada com 59 artigos) e, também, com maior disseminação em vários países.

Assaf Neto e Silva (2012, p. 143) esclarecem, ainda, que:

Para empregar tal instrumento é necessário que a empresa possua uma série histórica de seus clientes. Com esta série histórica é possível classificar, a priori, os clientes: se efetuaram os pagamentos dentro das condições preestabelecidas ou não. Acredita-se que é possível caracterizar o grupo de bons clientes e separá-los dos outros a partir de informações quantitativas.

No que tange à modelagem, Hair et al. (2009) afirmam que a Análise Discriminante pode ser vista como uma técnica estatística apropriada, quando se tem uma variável dependente e categórica (nominal ou não métrica) e as variáveis independentes por sua vez são métricas.

Por isto, a função discriminante se mostra adequada à construção de um modelo matemático para verificar a inadimplência no crédito. Este modelo terá como objetivo básico responder se um aspirante a crédito pertence a um grupo de empresas solventes ou a um grupo de empresas insolventes.

Virgillito e Famá (2008) salientam que, existindo dois grupos de empresas, solventes (A) e insolventes (B), sejam duas medidas V_1 e V_2 (suas observações, indicadores), sejam as elipses A e B (desenhadas com pontos pequenos e pontos grandes, ver FIGURA 5) seus universos, seja Z o eixo determinado pela sua função discriminante que, por sua vez, é constituída por indicadores. Se traçar uma linha reta, por meio da área de interseção das duas elipses e projetar esta linha num novo eixo Z, segundo Hair et al. (2009), pode-se afirmar que a área de sobreposição entre as duas distribuições univariadas A e B (representada pela área sombreada, ver FIGURA 5) será a menor entre todas as outras retas possíveis de serem traçadas por meio da área de sobreposição das duas elipses.

A área de sobreposição, na Figura 5, que está projetada sobre o eixo Z, pode ser interpretada como a discriminação entre os dois grupos, que são os

indicadores das empresas insolventes e solventes. Sendo assim, quanto menor for a área de sobreposição, menor será o número de empresas insolventes, classificadas como solventes e vice-versa. Consequentemente, menor será a probabilidade de conceder crédito a uma empresa insolvente.




Figura 5 Representação gráfica da análise discriminante de dois grupos
Fonte: Adaptado de Hair et al. (2009, p. 230)

A equação que representa uma combinação linear, para a Análise Discriminante, ou seja, a função discriminante assume a seguinte forma:

$$Z_{jk} = a + W_1 X_{1k} + W_2 X_{2k} + W_3 X_{3k} + \dots + W_n X_{nk} \quad (05)$$

Em que:

Z_{jk} = variável dependente ou score Z discriminante da função discriminante j para o objeto k ;

a = intercepto da função quando todo $X_i = 0$;

W_i = peso discriminante para a variável independente i ;

X_{ik} = variável independente i para o objeto k .

É importante observar que, na Função Discriminante criada por Fisher, também conhecida como Função de Classificação, não se utiliza a constante a (intercepto), o que simplifica a interpretação dos valores gerados para W_i , em razão de estes se aproximarem dos valores reais quando a intercepto não está presente na função. Por este método, os valores de observação, para as variáveis (independentes), são inseridos na função de Fisher e um escore de classificação para cada grupo é calculado para aquela observação, então, ela é classificada no grupo com maior escore de classificação (HAIR et al., 2009).

Mateus (2010) observa que, com base na função discriminante (ou função de classificação), obtém-se um escore Z discriminante que representa o resultado composto da multiplicação de cada variável independente por seu peso correspondente. A discriminação dos grupos ocorre, por meio do estabelecimento dos pesos da variável estatística (variável predita não métrica), para cada variável preditora, no intuito de maximizar a variância entre os grupos e dentro de cada grupo.

Considera-se que a função discriminante identifica, eficientemente, os grupos se a sobreposição das distribuições dos escores discriminantes para os grupos for pequena (HAIR et al., 2009).

Já, para testar a significância estatística da função discriminante, pode-se verificar a distância entre os centroides (média) de cada grupo, ou seja, a medida do afastamento entre os grupos que estão em análise.

Os centroides são o resumo das diferenças entre cada grupo e representam a média de cada grupo, o que possibilita o cálculo do ponto de corte ótimo ou escore crítico. Também permite o cálculo do valor médio entre as médias de cada grupo e a discriminação de novos indivíduos ou objetos.

Quando as amostras possuem tamanhos iguais, o ponto de corte ótimo pode ser obtido pelo cálculo do valor médio das médias dos grupos (FIGURA 6). Deste modo, pode ser definido como:

$$Z_{EC} = \frac{Z_A + Z_B}{2} \quad (06)$$

Em que:

Z_{EC} = escore de corte crítico para amostras de mesmo tamanho;

Z_A = centroide do grupo A;

Z_B = centroide do grupo B.



Figura 6 Amostra de tamanhos iguais
Fonte: Corrar et al. (2014, p. 239)

Todavia, as amostras utilizadas podem apresentar tamanhos diferentes (FIGURA 7). Há, então, a existência de dois escores discriminantes distintos para cada grupo e a solução mais adequada é ponderar tais escores, atribuindo-lhes peso, tendo em vista a quantidade de indivíduos ou objetos de cada amostra em questão (MATEUS, 2010).

Pode-se obter o escore de corte ótimo para amostra de tamanhos diferentes da seguinte forma:

$$Z_{ED} = \frac{N_A Z_B + N_B Z_A}{N_A + N_B} \quad (07)$$

Em que:

Z_{ED} = escore de corte crítico para amostras de tamanhos diferentes;

N_A = quantidade de observações do grupo A;

N_B = quantidade de observações do grupo B;

Z_A = centroide para o grupo A;

Z_B = centroide para o grupo B.




Figura 7 Amostra de tamanhos diferentes
 Fonte: Corrar et al. (2014, p. 239)

Hair et al. (2009), ainda, salientam que, para validar a função discriminante pelo uso de matrizes de classificação, deve-se dividir a amostra em dois grupos. Um grupo será a amostra de análise, usada para computar a função discriminante e o outro será a amostra de teste (ou validação) retida para o uso na matriz de classificação.

Este procedimento consiste em multiplicar os pesos gerados pela amostra de análise pelas medidas originais da variável da amostra de teste. Em seguida, os escores discriminantes individuais, para amostra de teste, são comparados com o valor do escore de corte crítico e classificados como se segue:

Classificar no grupo A se $Z_n < Z_{ct}$ ou;

Classificar no grupo B se $Z_n > Z_{ct}$

Em que:

Z_n = escore discriminante para o n -ésimo indivíduo

Z_{ct} = valor do escore de corte crítico

O resultado deste procedimento de classificação é apresentado em forma de matriz, em que o percentual de classificado corretamente individual de cada grupo é apresentado e, também, o percentual geral de classificação correta para os dois grupos (também conhecido como razão de sucesso). Ou seja, a precisão de classificação correta do modelo de Análise Discriminante que foi gerado.

Uma alternativa interessante, após se ter calculado a Análise Discriminante, é a construção do termômetro de insolvência de Kanitz, que, por meio de uma escala ilustrada, indica três situações possíveis: insolvente (má situação), penumbra (o fator de insolvência não é suficiente para analisar o estado da empresa) e solvente (boa situação).

Para Carvalho (2004), na construção do "termômetro de insolvência", é necessário calcular o desvio padrão dos escores discriminantes para cada grupo. Logo depois de calculado o valor do desvio padrão, será somado e diminuído da média dos seus respectivos grupos, cria-se, assim, um intervalo entre a adição da média e do desvio padrão do grupo A e a subtração da média pelo desvio padrão do grupo B (FIGURA 8). Sendo assim, é possível classificar as empresas em três grupos distintos: insolventes, penumbra e solventes.

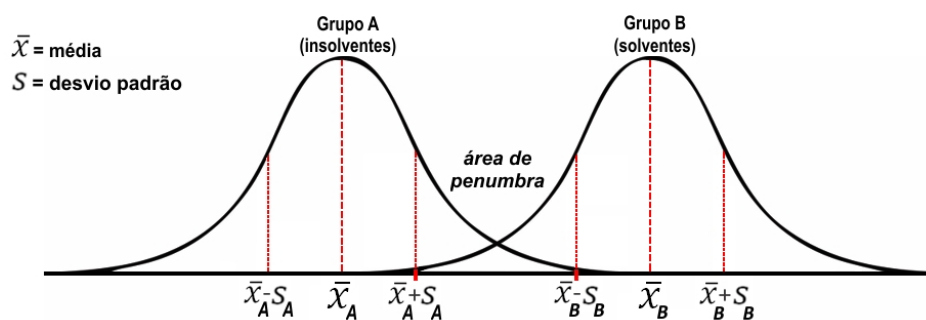


Figura 8 Identificação da área de penumbra, nas distribuições dos grupos
 Fonte: Elaborado pelo autor

Considerando-se a abrangência de um desvio padrão, para cada um dos grupos de empresas, existirá um intervalo que estará fora desta área. Segundo Kanitz (1978), este intervalo é denominado área de penumbra, o que significa que a empresa classificada nesta área está em uma situação indefinida e deve inspirar cuidados.

Estatisticamente, observa-se que o modelo matemático não tem base para afirmar nenhuma classificação neste intervalo.

2.4.1.1 Pressupostos da análise discriminante

Como ocorre em todas as técnicas multivariadas de dados, a análise discriminante precisa atender diversos pressupostos que se relacionam ao processo estatístico envolvido além de questões que influenciam a interpretação dos resultados (HAIR et al., 2009).

Corrar et al. (2014) enfatizam que os pressupostos da análise discriminante são: Normalidade multivariada; Linearidade; Ausência de *outliers*; Ausência de multicolinearidade; e Homogeneidade das matrizes de variância-co-variância.

Para Hair et al. (2009), primeiramente, deve-se verificar a normalidade multivariada (distribuição, aproximadamente, normal) das variáveis independentes. Neste sentido, para calcular o nível de significância para as diferenças em relação a uma distribuição normal, pode-se utilizar dos testes de Shapiro-Wilks e uma modificação do teste de Kolmogorov-Smirnov. Para os casos, em que a variável não apresente a normalidade multivariada, pode-se realizar uma transformação de Box-Cox com intuito de normalizar a distribuição da variável.

Em segundo, no que se refere à linearidade das variáveis, Hair et al. (2009) observam que é uma proposição implícita, visto que a função discriminante não reflete as relações não lineares, a menos que transformações particulares (em variáveis) sejam executadas para representar efeitos não lineares.

Hair et al. (2009, p. 237) explicam que as “matrizes de covariância desiguais, também, afetam negativamente o processo de classificação. Se os tamanhos das amostras são pequenos e as matrizes de covariância são diferentes, então, a significância estatística do processo de estimação é afetada adversamente”. O teste, para verificar a igualdade das matrizes de covariância, é o teste Box's M.

A multicolinearidade significa que duas ou mais variáveis independentes estão altamente correlacionadas, de modo que uma variável pode ser altamente explicada ou prevista pela outra variável (ou outras variáveis), o que acrescenta pouco ao poder explicativo do grupo de variáveis (HAIR et al., 2009).

2.4.2 Regressão logística - RL

Bellovary, Giacomino e Akers (2007) destacam a tendência da passagem dos estudos sobre crédito, utilizando análise discriminante, em 1960 e 1970, para trabalhos utilizando análise logit na década de 1980. O trabalho que introduziu a técnica de *logit* na previsão de falência foi o estudo de Ohlson (1980) denominado *Financial ratios and the probabilistic prediction of bankruptcy*. Nesta pesquisa, o autor apresentou ao campo de estudo uma nova possibilidade para a previsão do fracasso empresarial como evidenciado pelo caso de falência.

Neste ponto, a regressão logística (*logistic regression* ou *logit analysis*) é uma modelagem matemática que tem por função descrever a relação entre diversas variáveis independentes e uma variável dependente. Ela permite estimar diretamente a probabilidade de ocorrência de determinado evento. Observa-se, também, que entre todos os modelos matemáticos, que podem ser utilizados para esta finalidade, o logístico é um dos mais usuais.

Guimarães e Chaves Neto (2002) observam que a regressão logística consiste, basicamente, na busca de um modelo que permita relacionar uma variável y , chamada “variável resposta” (variável dependente), aos “fatores” (variáveis independentes) $X_{1i}, X_{2i}, \dots, X_{ni}$ que se supõe influenciar as ocorrências de um evento. A variável resposta, no entanto, deve ser do tipo dicotômica, assumindo apenas dois valores possíveis 0 ou 1. Neste caso, existe interesse apenas na ocorrência, ou não, do evento em questão.

O modelo de regressão logística pode ser representado por uma função da seguinte forma:

$$P(Y = 1) = \frac{1}{1 + e^{-(x)}} \quad (08)$$

Em que:

$P(Y=1)$ = é a probabilidade relativa que um determinado evento ocorra;

$e \cong 2,718$;

$$(x) = B_0 + B_1X_{1i} + B_2X_{2i} + \dots + B_nX_{ni}$$

Em que:

B_0 é uma constante e B_1, B_2, \dots, B_n são os coeficientes estimados a partir dos dados de $X_{1i}, X_{2i}, \dots, X_{ni}$ (variáveis independentes).

Hosmer e Lemeshow (1989), ainda, pontuam que os coeficientes B_0, B_1, \dots, B_n são estimados com base no conjunto de dados em questão, pelo método da máxima verossimilhança, que encontra uma combinação de coeficientes que maximiza a probabilidade da amostra ter sido observada. Considerando certa combinação de coeficientes B_0, B_1, \dots, B_n e variando os valores de X , observa-se que a curva logística tem comportamento probabilístico no formato da letra S (FIGURA 9).




Figura 9 Função Sigmoide

Fonte: Guimarães e Chaves Neto (2002, p. 8)

Para estimar o modelo de regressão logística, esta função sigmoide (curva logística) é ajustada aos dados reais. Por exemplo, a Figura 10 representa

dois exemplos hipotéticos, A e B, em que a probabilidade de ocorrer ou não determinado evento é representado no topo e na base da função sigmoide.

Na função sigmoide A, a curva logística não pode ajustar bem os dados, porque há alta sobreposição das distribuições (diversos valores da variável independente que tem eventos e não eventos), o mesmo já não ocorre na função sigmoide B, porque ela possui uma relação mais bem definida e a curva logística ajusta-se muito bem aos dados (HAIR et al., 2009).

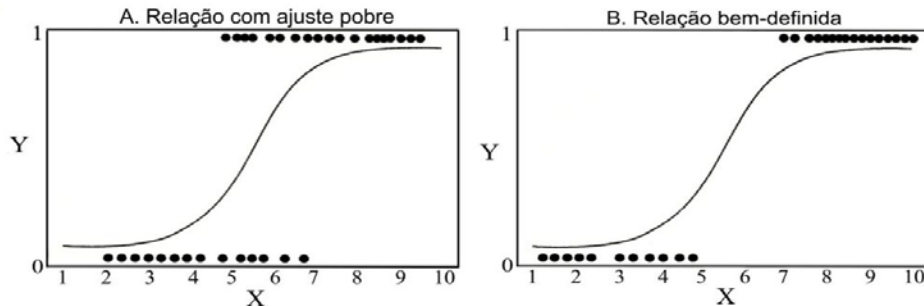


Figura 10 Exemplos de ajuste da curva logística a dados de amostra
Fonte: Hair et al. (2009, p. 285)

Esse formato, dada a regressão logística, possui um alto grau de generalidade, aliada a aspectos muito desejáveis, tais como:

1º - Quando $(x) \rightarrow +\infty$, então $P(Y = 1) \rightarrow 1$

2º - Quando $(x) \rightarrow -\infty$, então $P(Y = 1) \rightarrow 0$

Assim, pode-se tanto estimar diretamente a probabilidade de ocorrência de um evento quanto estimar a probabilidade de não ocorrência do mesmo por meio da diferença:

$$P(Y = 0) = 1 - P(Y = 1) \quad (09)$$

Entretanto, segundo Corrar et al. (2014), o primeiro passo para dar início à regressão logística é converter a probabilidade associada a cada observação em razão de chance (*odds ratio*), ou seja, a possibilidade de sucesso comparada a de fracasso.

Esta relação pode ser expressa da seguinte forma:

$$\text{Razão de chance} = \frac{P(\text{sucesso})}{1 - P(\text{sucesso})} \quad (10)$$

Ao utilizar-se da regressão logística, para facilitar a interpretação dos resultados, a principal suposição é a de que o logaritmo da razão entre as probabilidades de ocorrência e não ocorrência do evento é linear, conforme segue:

$$\frac{P(\text{sucesso})}{1 - P(\text{sucesso})} = e^{B_0 + B_1 X_{1i} + B_2 X_{2i} + \dots + B_n X_{ni}} \quad (11)$$

E, por consequência,

$$\ln \left[\frac{P(\text{sucesso})}{1 - P(\text{sucesso})} \right] = B_0 + B_1 X_{1i} + B_2 X_{2i} + \dots + B_n X_{ni} \quad (12)$$

Por essa razão, segundo Garson (2015), ao fazer a interpretação dos coeficientes da regressão logística, opta-se por interpretar o e^B e não diretamente o B . Contudo, é preciso observar que, quando se utiliza o modelo logístico do ponto de vista de discriminação entre grupos, não há um grande interesse na interpretação dos coeficientes.

Para utilizar o modelo de regressão logística para discriminação de dois grupos, a regra de classificação é a seguinte: se $P(Y=1) > 0,5$ classifica-se $Y=1$; se $P(Y=1) < 0,5$ classifica-se $Y=0$.

Como P (probabilidade) sempre se situa entre 0 e 1, o escore Z é, frequentemente, interpretado como a probabilidade relativa de ocorrência de um determinado evento.

Portanto, o presente modelo logístico se mostra aplicável, a princípio, para ser utilizado na estimação de uma série de indicadores (indicadores já conhecidos), no intuito de definir a probabilidade de uma empresa ser enquadrada no grupo das insolventes. A variável dependente (Y) indica se a empresa é insolvente ($=1$) ou solvente ($=0$) e a série de indicadores (X_1, X_2, \dots, X_n) constitui conjunto de variáveis independentes (indicadores).

2.4.2.1 Validação dos Resultados

Corrar et al. (2014) afirmam que a regressão logística tem sido amplamente adotada em decorrência de seu pequeno número de suposições. Segundo os autores, pelo fato de os parâmetros da regressão logística serem estimados pelo método da máxima verossimilhança, a regressão logística não apresenta a necessidade de pressupostos dos métodos estimados pelos mínimos quadrados, tais como distribuição F, distribuição t, R-Quadrado, entre outras.

Entretanto, apesar da sua flexibilidade, Hair et al. (2009) afirmam que a baixa correlação entre as variáveis independentes deve ser observada, tendo em vista que o modelo de regressão logística é sensível à colinearidade entre as variáveis. Corrar et al. (2014) apresentam quatro medidas de avaliação para o modelo logístico: o *Likelihood Value*, o R-Quadrado, o teste de Hosmer e Lemeshow e o teste *Wald*.

O *Likelihood Value* é um indicativo da capacidade que o modelo possui para estimar a probabilidade associada à ocorrência ou não de determinado evento. O *Likelihood Value* serve, também, para verificar se o modelo melhora com a inclusão ou exclusão de alguma variável independente – particularmente, quando se opta pelo método *stepwise* que tem por finalidade identificar as variáveis que apresentam maior poder preditivo. Em resumo, pode-se afirmar que o principal objetivo do *Likelihood Value* é verificar se a regressão é estatisticamente significativa e facilitar comparações entre modelos alternativos (CORRAR et al., 2014).

Outra observação importante é que o modelo logístico não possui um determinante objetivo como o R^2 da regressão linear. Entretanto, segundo Corrar et al. (2014), ele possui pseudos- R^2 , tais como: os testes Cox-Snell e o teste Nagelkerke. O Nagelkerke é um ajuste para o teste Cox-Snell, que visa tornar os seus resultados mais compressivos, situando-o em uma escala de 0 a 1. Os autores, ainda, afirmam que os testes devem ser utilizados apenas como uma medida aproximada do poder preditivo de cada modelo. Entretanto, indicadores que vão de 0 a 1 podem ser úteis na avaliação e comparação dos modelos.

Corrar et al. (2014, p. 296) enfatizam que outro mecanismo que pode auxiliar no grau de acurácia do modelo é o teste de Hosmer e Lemeshow, que tem por finalidade “verificar se existem diferenças significativas entre as classificações realizadas pelo modelo e a realidade observada. Em certo nível de significância, busca-se aceitar a hipótese de que não existem diferenças entre os valores preditivos e observados”.

Por último, a estatística Wald tem por finalidade auferir o grau de significância de cada coeficiente da equação logística (inclusive da constante), isto é, esse mecanismo tem por objetivo verificar se cada parâmetro estimado é, significativamente, diferente de 0 (CORRAR et al., 2014).

Deste modo, quando um problema envolve uma variável dependente dicotômica, uma solução viável, para se contornar alguns problemas (métodos elaborados, limitações da regressão múltipla, uso da análise discriminante e pressupostos estatísticos não satisfeitos), é a implantação da regressão logística, que pode oferecer um método de análise eficiente e capaz de lidar com esse tipo de situação (HAIR et al., 2009).

2.4.3 Redes neurais artificiais - RNA

Bellovary, Giacomino e Akers (2007) observam que, após os altos níveis de utilização da análise discriminante, nas décadas de 1960 e 1970 e da análise logit, na década de 1980, observou-se na área de risco de crédito uma nova tendência nos estudos realizados a partir da década de 1990, qual seja, a utilização de técnicas de inteligência artificial, as redes neurais.

O trabalho pioneiro, no campo da previsão de falências, utilizando as técnicas das redes neurais artificiais foi o estudo de Odom e Sharda (1990) intitulado *A Neural Network Model for Bankruptcy Prediction*. Esse estudo viria propor uma nova direção, para as modelagens utilizadas no campo, abrindo novas possibilidades além das técnicas de análise discriminante e regressão logística.

Desde então um grande número de pesquisadores tem utilizado de redes neurais para a avaliação dos riscos referentes à insolvência empresarial por meio de indicadores econômico/financeiros. Entre eles, podem-se destacar Abiyev (2014), Altman, Março e Varetto (1994), Atiya (2001), Chuang e Huang (2011), Huang et al. (2004), Iturriaga e Sanz (2015), Khashei et al. (2013), Lee e Choi (2013), Odom e Sharda (1990) e Wilson e Sharda (1994).

Almeida e Nakao (2014) salientam que uma das técnicas mais recentes para tratamentos de dados, que tem despertado grande interesse, tanto de pesquisadores da área de tecnologia quanto da área de negócios, é a de redes neurais artificiais.

Braga et al. (2011) explanam que as redes neurais artificiais (RNAs) ressurgiram, no final da década de 1980 e, também, são conhecidas como *conexionismo* ou *sistemas de processamento paralelo e distribuídos*. Segundo os autores, “essa forma de computação não algorítmica é caracterizada por sistemas que, em algum nível, relembram a estrutura do cérebro humano. Por não ser baseada em regras, a computação neural se constitui em uma alternativa à computação algorítmica convencional” (BRAGA et al., 2011, p. 3).

Haykin (2001) observa que as pesquisas com redes neurais artificiais (usualmente denominadas de redes neurais) têm se expandido em decorrência ao fato do reconhecimento de que o cérebro humano processa informações de maneira inteiramente diferente de um computador convencional.

O cérebro é um computador (sistema de processamento de informação), altamente complexo, não linear e paralelo e constituído, basicamente, por unidades estruturais elementares chamadas de neurônios (unidades de processamento), que podem apresentar diversas entradas e saídas, estando maciçamente conectados entre si, na composição de uma rede neural (RN). Neste contexto, Haykin (2001, p. 28) define redes neurais como:

Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela se assemelha ao cérebro humano em dois aspectos: 1. O conhecimento é adquirido pela rede a partir de seu ambiente, através de um processo de aprendizagem. 2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Almeida e Nakao (2014, p. 433) afirmam que “a técnica de redes neurais artificiais é útil quando há a necessidade de se reconhecerem padrões a partir do acúmulo de experiências ou de exemplos, e cuja representação é complexa”.

2.4.3.1 O neurônio artificial: funcionamento

Haykin (2001) apresenta a unidade fundamental de processamento de uma rede neural artificial, o neurônio artificial. Os neurônios artificiais podem ser classificados em vários modelos. Entretanto, eles se diferenciam, basicamente, pelo tipo de entrada (binária ou contínua), tipo de saída e função de ativação que será utilizada. A representação de um neurônio base para o projeto de redes neurais (artificiais) é apresentado na Figura 11.

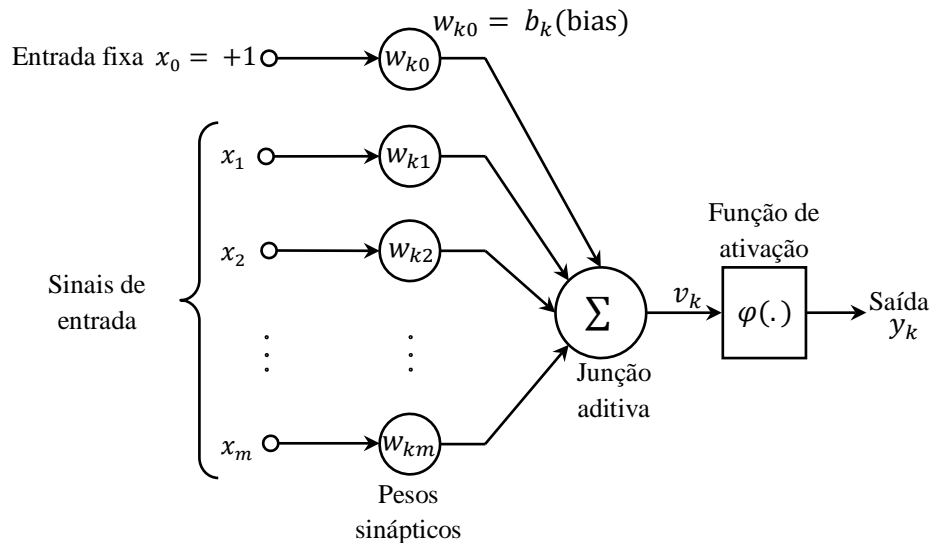


Figura 11 Modelo não linear de um neurônio
Fonte: Adaptado de Haykin (2001, p. 38)

Como observado por Haykin (2001), na Figura 11, podem-se visualizar três elementos básicos do modelo neural:

1. Um conjunto de sinapses, cada uma caracterizada por um peso próprio. Cada sinal x_j na entrada da sinapse j ligada ao neurônio k e multiplicada pelo peso sináptica w_{kj} , em que o primeiro subscrito indica o neurônio (k) em questão e o segundo se refere ao terminal de entrada da sinapse (j), à qual o peso se refere;

2. Uma função soma que realiza o somatório de todos os sinais de entrada, ponderados pelos seus respectivos pesos.

3. Uma função de ativação, para decidir acerca da transmissão do sinal (impulso) de um neurônio. Esta função, também, restringe a amplitude de sinal de saída a um valor finito. Normalmente este é escrito em intervalo unitário fechado $[0, 1]$ ou alternativamente $[-1, 1]$.

Outro elemento de entrada, demonstrado por Haykin (2001), para o processamento do modelo neuronal, é o **bias**, representado por b_k . Ele tem o efeito de aumentar, se positivo e de diminuir, se negativo, a entrada líquida da função de ativação. O efeito do bias pode ser levado em conta de duas maneiras: adicionando um sinal de entrada fixo em $+1$ e sendo um peso sináptico igual ao bias b_k . Este procedimento pode ser representado de forma matemática como se segue:

$$\begin{aligned} x_0 &= +1 \\ e \\ w_{k0} &= b_k \end{aligned} \tag{13}$$

Em que:

x_0 sinal de entrada fixa do neurônio;

w_{k0} peso sináptico do neurônio k na entrada fixa;

b_k é o bias aplicado ao neurônio k correspondente ao w_{k0} .

O funcionamento deste neurônio, tendo em consideração o bias como um peso sináptico, pode ser descrito matematicamente pelas seguintes equações:

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (14)$$

e

$$y_k = \varphi (v_k) \quad (15)$$

Em que:

j é o índice das m entradas do neurônio;

x_j são os sinais de entrada do neurônio;

w_{kj} são os pesos sinápticos do neurônio k ;

v_k chamado de campo local induzido, é a saída do combinador linear (em virtude dos sinais de entrada) somado ao bias do neurônio k ;

$\varphi (.)$ é a função de ativação do neurônio k e

y_k é o sinal de saída do neurônio.

Para a construção de um modelo de redes neurais artificiais, devem ser consideradas três características fundamentais, a saber: a arquitetura, que dá forma à rede (organização da rede em camadas); o algoritmo de aprendizado, mais eficaz para o modelo proposto (método para determinação dos pesos); e a função de ativação (que estipula os dados). Os tópicos a seguir darão maiores explicações destas características.

3.4.4 Principais tipos de função de ativação

Como dito anteriormente, um neurônio possui um estímulo de saída, que é controlado pela sua função de ativação. Esta função define se o sinal irá prosseguir (por isso é chamada de função de ativação), como também desempenha o papel de restringir a amplitude de saída de um neurônio, ficando no intervalo de $[0,1]$ ou $[-1, 1]$.

Alguns exemplos de funções de ativação utilizadas podem ser visualizados na Figura 12, que apresenta três tipos de funções de ativação, a saber: (a) função logística sigmoide (*logsig*); (b) função tangente hiperbólica (*tansig*) e (c) a função linear de ativação (*purelin*).

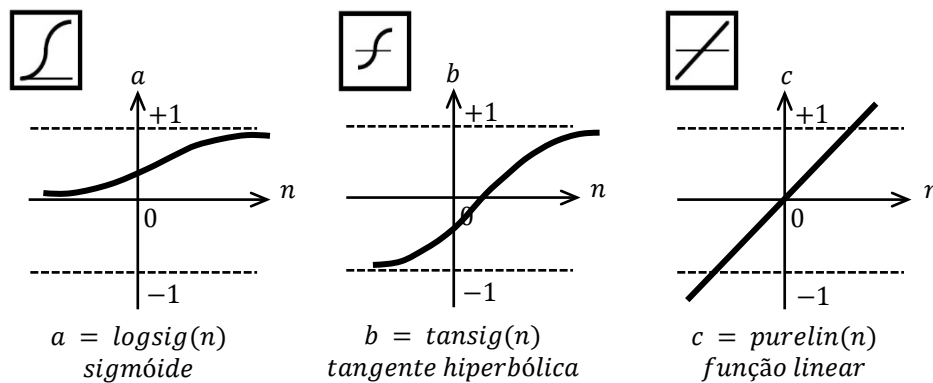


Figura 12 Funções de Ativação
Fonte: Adaptado de MathWorks (2012, p. 57-58)

Haykin (2001) enfatiza que a função logística sigmoide, cujo gráfico tem forma de S, é de longe a função de ativação mais utilizada na construção de redes neurais artificiais. Ela pode assumir valores entre $[0, 1]$. Conforme pode ser observado na Equação 16, a é o parâmetro de inclinação da função sigmoide.

$$\varphi(v) = \frac{1}{1 + e^{-(av)}} \quad (16)$$

Algumas vezes, é desejável que a função de ativação se estenda no intervalo de $[-1, +1]$, assumindo uma forma antissimétrica em relação à origem. A função tangente hiperbólica pode ser utilizada, neste caso, por assumir valores no intervalo de $[-1, +1]$ e por ser correspondente a uma função sigmoide. O fato de utilizar uma função do tipo sigmoide, que assuma valores negativos, traz benefícios analíticos ao modelo (HAYKIN, 2001). A função tangente hiperbólica pode ser vista na Equação 17:

$$\varphi(v) = \text{tang}(v) \quad (17)$$

Os neurônios de saída sigmóides apresentados acima são utilizados, na maioria das vezes, para problemas de reconhecimento de padrões, enquanto os neurônios que possuem saída linear são utilizados para problemas da função de ajuste (MATHWORKS, 2012). A função de ativação linear pode ser vista na Equação 18, em que se tem: a como um número real, que com base nos valores de entrada define a saída linear; $\varphi(v)$ a saída; e x a entrada, como se pode visualizar abaixo:

$$\varphi(v) = ax \quad (18)$$

As três funções de transferência descritas são as funções mais utilizadas para a criação das redes de múltiplas camadas. Entretanto, outras funções de transferência podem ser criadas e utilizadas, conforme as necessidades de cada modelo de pesquisa (MATHWORKS, 2012).

2.4.3.2 Redes *perceptron* de multicamadas

Neste tópico, são abordadas as redes *perceptron* de multicamadas. O objetivo da abordagem destas redes é dar fundamentação ao presente estudo realizado, tendo em vista que as características do *perceptron* de multicamadas parecem atender ao tipo de pesquisa realizada.

Almeida e Nakao (2014) enfatizam que a arquitetura utilizada pela rede neural artificial pode restringir o tipo de problema a ser analisado. Os autores observam que as redes sem camadas escondidas (*perceptron* de uma única camada) conseguem fazer apenas separações lineares. Entretanto, as redes multicamadas (*perceptron* de multicamadas) são apropriadas para análise de problemas mais complexos e conseguem separar qualquer função contínua, sendo ela linear ou não linear.

As redes *perceptron* de múltiplas camadas (MLP, do inglês *Multi Layer Perceptron*), apresentam uma capacidade computacional muito superior a das redes *perceptron* de uma única camada (sem camadas intermediárias), porque possuem a capacidade de tratar dados que não são linearmente separáveis (HAYKIN, 2001).

Russell e Norvig (2004, p. 720) ressaltam que:

A vantagem de adicionar camadas ocultas é que ela aumenta o espaço de hipóteses que a rede pode representar. [...] De fato, com uma única camada oculta suficientemente grande, é possível representar qualquer função contínua das entradas com exatidão arbitrária; com duas camadas, até mesmo funções descontínuas podem ser representadas.

Uma rede multicamadas, para Haykin (2001), compreende três elementos básicos:

1. Os nós, que são o elemento básico das redes neurais, e que atuam no processamento, em paralelo com os outros nós da rede.

2. A rede neural, que é um arranjo sequencial de três tipos básicos de nós ou camadas: nós (neurônios) de entrada (recebem os dados iniciais e transmitem para a rede), nós intermediários e os nós de saída.

3. E a capacidade de aprendizado, que segundo Haykin (2001) é o que realmente diferencia uma rede neural de outras técnicas multivariadas. Neste processo, os valores são propagados pela rede, por meio de pesos de conexão entre os nós, e os pesos de conexão são ajustados por meio de um método de aprendizado.

Ludwig Junior e Montgomery (2007) comentam que o *perceptron* de múltiplas camadas possui uma camada sensorial (entrada), uma ou mais camadas ocultas e uma camada de saída. O sinal se propaga para a frente da camada sensorial até a camada de saída, isto é, a rede é alimentada para a frente (*feedforward*).

Segundo Braga et al. (2011), o papel das multicamadas em uma rede *feedforward*, como é o caso da rede MLP, é de transformar, sucessivamente, o problema descrito pelos dados no espaço de entrada em uma representação que seja tratável para a camada de saída.

Por exemplo, em um problema não linearmente separável que é resolvido por uma rede de duas camadas, a camada intermediária transforma-o em um problema linearmente separável, criando uma nova disposição interna à rede para os dados de entrada. A partir desta disposição, agora linearmente separável, a camada de saída tem condições de resolver o problema descrito no espaço de entrada da rede (BRAGA et al., 2011).

Braga et al. (2011) destacam que as duas transformações sucessivas que representam este comportamento são: $H(x, w_H)$, referente à camada intermediária, e $Y(H(x, w_H); w_S)$, relativa à camada de saída, em que o vetor de

peso w_H corresponde à camada oculta e w_s é o vetor de peso que corresponde à camada de saída.

Como pode ser observado na Figura 13, o problema não linearmente separável é transformado em um problema linearmente separável, por meio do mapeamento realizado pela camada escondida. A superfície de separação não linear descrita no espaço de entrada é obtida por meio do mapeamento sucessivo da rede nas duas camadas (BRAGA et al., 2011).

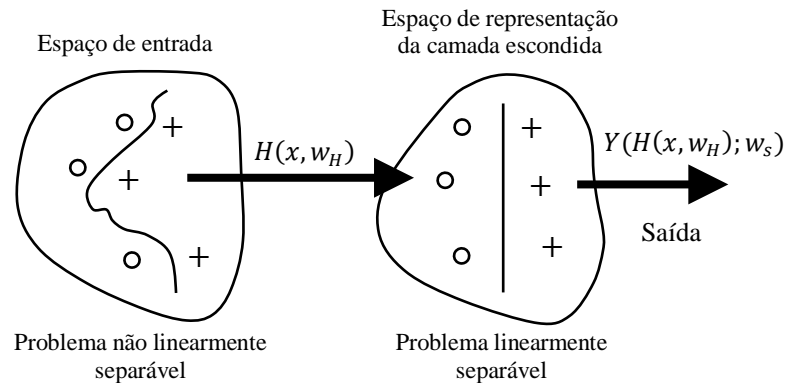


Figura 13 Esquema do mapeamento sucessivo em camadas realizado por uma rede PLP
Fonte: Adaptado de Braga et al. (2011, p. 17)

Neste sentido, Braga et al. (2011) salientam que o mapeamento no espaço relativo à camada oculta separa os elementos da classe “o” dos elementos da classe “+”, possibilitando a resolução do problema por meio de uma reta. O mapeamento da função $H(x, w_H)$ tem como resultado a superfície não linear, representada no espaço de entrada. A execução da superfície linear no espaço de representação da camada oculta é realizada pela função $Y(H(x, w_H); w_s)$ da camada de saída.

2.4.3.3 Algoritmo *back-propagation*

Braga et al. (2011) explicam que o algoritmo de treinamento mais popular para o *perceptron* de multicamadas é o de retropropagação do erro (*back-propagation*) que, por ser supervisionado, ajusta os pesos da rede por meio de um mecanismo de correção de erros, utilizando pares de entrada e saída (x, y_d). A maioria das *perceptron* de multicamadas utiliza variações deste algoritmo.

A aprendizagem, por meio do algoritmo *back-propagation*, consiste em dois passos por meio das camadas da rede, *forward* e *backward*. A fase *forward* (um passo à frente) é a propagação utilizada para definir a saída da rede para certo padrão de entrada. A fase *backward* (um passo para trás) é a retropropagação, que utiliza a saída desejada e a saída fornecida pela rede para corrigir os pesos das conexões da rede (BRAGA et al., 2011).

Nesse sentido, os dados seguem da entrada para a saída (*forward*) e, os erros, da saída para a entrada (*backward*). Este processo pode ser visualizado na Figura 14.

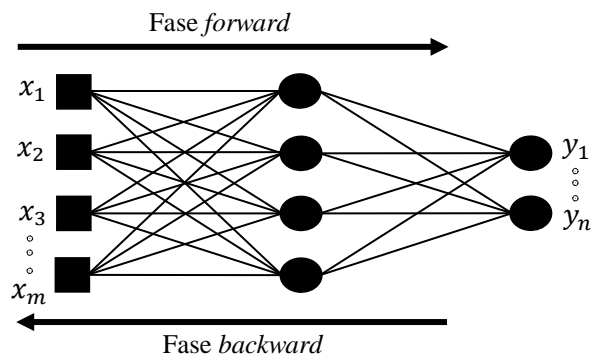


Figura 14 Fluxo de processamento do algoritmo *back-propagation*
 Fonte: Adaptado de Braga et al. (2011, p. 74)

De acordo com Braga et al. (2011), o passo para a frente (*forward*) envolve as seguintes etapas:

1. O vetor de entrada x é apresentado à primeira camada da rede, e as saídas dos neurônios da primeira camada escondida C_1 são calculadas.

2. As saídas da camada oculta C_1 serão destinadas à camada seguinte C_2 , para que elas sejam, então, calculadas. Este processo se repete até que se chegue à última camada C_k .

3. As saídas produzidas pelos neurônios da última camada são, então, comparadas às saídas desejadas y_d para aquele vetor de entrada x , e o erro correspondente $y_d - y$ é calculado.

É possível observar que o objetivo na fase *forward* (passo para a frente) é obter o erro de saída ao final da propagação do sinal por todas as camadas da rede. Já a fase *backward* (um passo para trás) envolve as seguintes etapas (BRAGA et al., 2011):

1. O erro encontrado na camada de saída C_k é usado para o ajuste de pesos, por meio do gradiente descendente de erro (vetor que modifica os pesos sinápticos, na direção oposta à direção de maior aumento do erro médio quadrático, minimizando, assim, o erro médio quadrático).

2. Os erros dos neurônios da camada de saída C_k são enviados para a camada anterior C_{k-1} , e, para isto, são multiplicados os pesos das conexões entre as camadas por seus erros correspondentes. Tem-se, assim, um erro estimado para cada neurônio da camada oculta, representando uma medida da influência de cada neurônio da camada C_{k-1} no erro da saída da camada C_k .

3. O erro calculado para o neurônio da camada C_{k-1} é utilizado para ajustar os pesos, por meio do gradiente descendente, de forma semelhante ao procedimento utilizado para a camada C_k .

4. Este processo se repete até que os pesos da camada C_1 sejam ajustados, concluindo-se, assim, o ajuste dos pesos de toda a rede para o vetor de entrada x e sua saída desejada y_d .

Como mencionado por Braga et al. (2011), o ajuste dos pesos feito pelo algoritmo de retropropagação do erro (*back-propagation*) é baseado na regra delta proposta por Windrow e Hoff, em 1960, utilizada para treinar redes Adaline. A utilização desse algoritmo de forma generalizada para redes de múltiplas camadas é chamada de regra delta generalizada ou *back-propagation*. A derivação da regra delta generalizada é semelhante à derivação da regra delta.

Braga et al. (2011) destacam que a função custo a ser minimizada é uma função de erro, que é definida pela soma dos erros quadráticos. Os autores demonstram como este procedimento pode ser realizado, por meio da dedução de equações (sem perda de generalidade, baseando-se em uma rede de duas camadas), como se segue:

Um neurônio j possui uma saída linear u_j correspondente à soma ponderada de suas entradas e uma saída moralmente não linear y_j obtida após a aplicação da função de ativação sobre u_j , isto é, $y_j = f(u_j)$. Para diferenciar as respostas dos neurônios das camadas de saída e camadas ocultas, estes últimos terão suas saídas referenciadas como $h(u_i)$ para um neurônio qualquer.

O erro de neurônio de saída j na interação n é definido por $e_j(n) = y_d^j(n) - y_j(n)$, sendo a soma dos erros quadráticos de todos os neurônios de saída na interação n definida pela Equação 19:

$$\varepsilon(n) = \frac{1}{2} \sum_j e_j^2(n) \quad (19)$$

Como a saída linear do neurônio j da camada de saída é definida por $u_j(n) = \sum_i h_i(n) w_{ji}(n)$, sendo o índice i referente à camada oculta, pode-se reescrever o erro do neurônio j como $e_j(n) = y_d^j(n) - f(u_j(n))$. Assim, a Equação 19 pode ser reescrita conforme a Equação 20:

$$\varepsilon(n) = \frac{1}{2} \sum_j (y_d^j(n) - f(u_j(n)))^2 \quad (20)$$

Maiores detalhes sobre as deduções da equação de ajuste da camada de saída e da camada escondida e, também, das variações do algoritmo de retropropagação do erro (*back-propagation*) podem ser encontradas na obra de Braga et al. (2011).

Haykin (2001) ressalta que o objetivo do método de retropropagação é processar uma grande quantidade de casos, por meio da rede neural, na fase de aprendizado, para que, desta forma, a rede possa realizar as melhores previsões possíveis ao longo de todas as observações de entrada. Swales e Yoon (1992) destacam que as técnicas de inteligência artificial (redes neurais artificiais) têm como diferencial a capacidade para aprender, por meio de um processamento iterativo, que visa minimizar os erros preditivos, isto é, a diferença entre as saídas atuais e as saídas projetadas.

Almeida e Nakao (2014) elucidam que, depois de ter passado por um número suficiente de exemplos da amostra de análise, os pesos na rede não têm mais alterações significativas e o erro não se reduz mais. É neste ponto que o treinamento da rede é encerrado, ou seja, a rede aprendeu a reconhecer as entradas.

2.4.4 Avaliação dos modelos

Baesens et al. (2003) estudaram o desempenho de várias técnicas de classificação de crédito. Segundo os autores, as mais tradicionais são regressão logística e análise discriminante. Entretanto, recentemente, foram propostas para esse problema algumas novas metodologias como *support vector machines* e *least-squares support vector machines (LS-SVMs)*, dentre outras (HARRIS, 2013; YANG; YOU; JI, 2011; YEH; CHI; HSU, 2010; YU, 2014).

Mesmo com resultados mais promissores, é preciso considerar as limitações de cada modelagem. Nas pesquisas empíricas que utilizam mais de uma técnica para avaliar o risco de crédito é possível comparar a sua acurácia por meio de testes como a Curva ROC (*Receiver Operating Characteristics*) e o teste de Kolmogorov-Smirnov - KS. Segundo Crone e Finlay (2012), medidas de separação de grupos, tais como a área sob a curva ROC (AUC) e a estatística KS, são amplamente utilizados para avaliar o desempenho dos modelos.

Segundo Sicsú (2010, p. 107-108), a curva ROC (*Receiver Operating Characteristic Curves*) baseia-se em duas definições: “sensitividade e especificidade. A sensitividade pode ser entendida como a capacidade de identificar os maus clientes; a especificidade pode ser entendida como a capacidade de identificar os bons clientes”. Complementando, Brito, Assaf Neto e Corrar (2009) explanam que a curva é obtida registrando em um gráfico “sensitividade” *versus* “1 - especificidade” para os diversos pontos de corte.

Flach (2010) salienta que, se uma técnica consegue realizar uma classificação com o mesmo nível de confiança com que ela determinada que uma dada entrada pertença à classe positiva (solvente), é possível, então, especificar vários pontos de corte. Sendo assim, os valores de sensibilidade e de especificidade apresentarão diferentes proporções sendo definidos pelos pontos de corte. Tendo em consideração todos os prováveis pontos de corte (em uma

escala de 0 a 1), pode-se ligá-los por um seguimento de reta, o que permite formar a ‘curva’ ROC.

A principal medida de desempenho que se pode obter a partir desse gráfico é o que se chama de AUC (*Area Under the Curve*), ou seja, o valor da área abaixo da curva. Soares e Rebouças (2015, p. 52) consideram que a AUC pode ser compreendida como “a probabilidade de uma observação positiva retirada aleatoriamente receba um escore maior do que uma observação negativa retirada da mesma maneira. Quanto melhor o ajustamento do modelo ao conjunto de dados, maior será a AUC, que varia entre 0 e 1”.

Já outra medida popular entre os analistas de risco de crédito, para avaliar o desempenho de modelos de *credit scoring*, é o teste de Kolmogorov-Smirnov – KS que, segundo Sicsú (2010, p. 105) e Sumihara Filho e Slegers (2010), representa a maior distância entre as funções de distribuição acumulada dos escores das empresas solventes e a das empresas insolventes.

Segundo Oliveira e Andrade (2002), os valores para KS podem variar entre 0 e 1 e, quanto mais o valor se aproxima de 1, maior será o poder de discriminação do modelo. Segundo os autores, modelos de *credit score* com KS acima de 50% não são muito corriqueiros para modelos desenvolvidos na concessão de crédito a novos clientes; entretanto, são mais facilmente encontrados para modelos de *behaviour score*, aplicados a bancos de dados de clientes já existentes, isso porque os indicadores do comportamento interno podem produzir um maior poder de discriminação nos modelos gerados.

Conover (1999) observa que a estatística de Kolmogorov-Smirnov - KS é baseada na distância existente entre as distribuições de probabilidades das empresas solventes e das empresas. Neste sentido, segundo o autor, o KS calcula a máxima separação entre a frequência relativa acumulada das Empresas Solventes, $F_{so}(s)$ e a frequência relativa acumulada das Empresas Insolventes,

Fin(s). Para a estatística não paramétrica, o teste de KS é utilizado pra identificar se duas amostras podem ser originárias de uma mesma função distribuição.

Sicsú (2010) e Sumihara Filho e Slegers (2010) salientam que alguns analistas costumam-se basear-se em alguns valores críticos de referência para o teste da AUROC e para o teste de Kolmogorov-Smirnov (KS), para determinar a eficácia dos modelos de *credit scoring*. Neste contexto, os autores observam que se pode utilizar um nível de precisão conforme o apresentado na Tabela 2.

Tabela 2 Poder discriminante: valores de referência da literatura

Hosmer e Lemeshow (Applied Logistic Regression, 1998, p. 162)		Sumihara Filho e Slegers (Behaviour Scoring, 2010, p. 44)	
<i>Área abaixo da curva ROC</i>	<i>Discriminação</i>	<i>Valores críticos para KS</i>	<i>Discriminação</i>
$\leq 0,5$	Não existe	$ks < 35$	Muito baixa
$> 0,5$ e $< 0,7$	Baixa	$35 \leq ks < 55$	Baixa
$\geq 0,7$ e $< 0,8$	Aceitável	$55 \leq ks < 65$	Aceitável
$\geq 0,8$ e $< 0,9$	Excelente	$65 \leq ks < 75$	Boa
$\geq 0,9$	Acima do comum	$ks \geq 75$	Excelente

Fonte: Adaptado de Sumihara Filho e Slegers (2010, p. 34-44)

Dentro da temática de risco de crédito e solvência, podem-se, ainda, citar alguns estudos recentes que utilizaram a curva ROC para avaliar a performance de modelos, entre eles destaca-se Ju e Sohn (2014), Kristof e Virag (2012), Kruppa et al. (2013), Nikolic et al. (2013), Sohn e Kim (2013), Tinoco e Wilson (2013), Wosnitza e Leker (2014) e Zhou, Lai e Yen (2014). Por sua vez, alguns dos trabalhos que utilizaram o índice de Kolmogorov-Smirnov – KS, para avaliar o desempenho dos modelos, são Crook, Edelman e Thomas (2007), Finlay (2011), Nikolic et al. (2013) e Selau (2008).

3 METODOLOGIA

Busca-se, neste tópico, apresentar de forma resumida, os delineamentos metodológicos que foram utilizados para atingir os respectivos objetivos da pesquisa.

3.1 Tipo de pesquisa

Para alcançar os resultados pretendidos com este trabalho, pode-se classificar esta pesquisa quanto aos fins, aos meios, aos tipos de dados e, ainda, quanto à forma de abordagem.

Quanto aos fins, este estudo pode ser classificado como predominantemente explicativo. A pesquisa explicativa visa esclarecer quais fatores contribuem, em algum nível, para a ocorrência de determinado fenômeno, tendo como principal objetivo tornar algo inteligível e justificar - lhe os motivos (ANDRADE, 2009; VERGARA, 2008).

No que tange aos meios, esta pesquisa pode ser caracterizada como *ex post facto*, tendo em vista que este tipo de pesquisa refere-se a um fato já ocorrido (VERGARA, 2008). Isto é, caracteriza-se, por meio de uma investigação sistemática e empírica, na qual o pesquisador não exerce controle direto sobre os indicadores em estudo (GIL, 2010).

Quanto aos tipos de dados secundários, foram utilizadas as pesquisas bibliográfica e documental. A pesquisa bibliográfica, segundo Marconi e Lakatos (2005), tem a finalidade de propiciar ao pesquisador o contato direto com tudo o que já foi realizado sobre determinado assunto: referências teóricas publicadas em artigos, livros, dissertações e teses. Em seguida, a pesquisa documental foi realizada nas demonstrações financeiras anuais, disponíveis na

base de dados Economática^{®2} e no site da BM&FBOVESPA³ (Bolsa de Valores, Mercadorias e Futuros).

Quanto à forma de abordagem, esta pesquisa é qualificada como quantitativa. Martins e Theóphilo (2009, p. 107) consideram que “[...] durante o processo de construção de um trabalho científico, o pesquisador, dependendo da natureza das informações, dos dados e das evidências levantadas, poderá empreender uma avaliação quantitativa [...]”. Segundo os autores, nesse tipo de pesquisa, os dados são quantificados e a validação da prova científica utiliza testes, graus de significância e sistematizações. Neste sentido, para o presente trabalho, optou-se por abordagens que envolveram procedimentos de estatística multivariada.

3.2 Amostragem

Para coleta das demonstrações contábeis das empresas insolventes, é preciso, primeiramente, definir o conceito de solvência utilizado no estudo. Para definição de insolvência, foi utilizada a lei de falência e concordatas: Lei n. 7.661, de 21 de junho de 1945 (BRASIL, 1945), que foi revogada pela Lei n.º 11.101, de fevereiro de 2005 (BRASIL, 2005), que passa a valer para todos os casos de falência e concordata atuais. Ou seja, o evento que determinará a entrada de uma empresa no estado de insolvência será apontado pela data em que a empresa tenha entrado com o pedido formal de Concordata Preventiva ou de Recuperação Judicial junto à Comissão de Valores Mobiliários (CVM) no

² Economática é uma ferramenta com um amplo banco de dados, utilizada para análise de investimento em ações. Foi fundada, em 1986, e é projetada para atender às necessidades de analistas.

³ BM&FBOVESPA (Bolsa de Valores, Mercadorias e Futuros) surgiu com a integração entre a BM&F (Bolsa de Mercadorias & Futuros) e a BOVESPA (Bolsa de Valores de São Paulo) em 2008.

período de 1995 a 2014. Como salienta Sanvicente e Minardi (1998, p. 1), a “previsão de concordatas é um aspecto essencial de modelos de gerenciamento de risco de crédito”.

Sendo assim, para a coleta dos indicadores das empresas insolventes, foi utilizada a data de um ano antes da empresa anunciar a falência (ano anterior do evento, tempo_{t-1}). Contudo, para se completar a amostra, seleciona-se, ao menos, uma empresa solvente para cada empresa insolvente, isto é, para cada empresa determinada insolvente, selecionar-se-á, no mínimo, uma empresa solvente pertencente ao mesmo setor e, quando possível, com ativos contábeis proporcionais ao da instituição insolvente. Essa metodologia baseia-se em estudos anteriores desenvolvidos por Altman (1968), Brito, Assaf Neto e Corrar (2009) e Sanvicente e Minardi (1998, 1999).

A lista com todas as empresas selecionadas pode ser visualizada no Quadro 4. São apresentadas as empresas insolventes selecionadas juntamente com a data do seu anúncio de pedido de Concordata Preventiva ou de Recuperação Judicial, além da(s) empresa(s) solvente(s) que foram utilizadas para equiparar a amostra.

Quadro 4 Amostra de Empresas solventes e insolventes

Setor Econômico	Ano do anúncio	Nº	Empresa Insolvente	Nº	Empresa Solvente
Química	1995	1	Aquatec (AQT4)	52	Polialden (PLDN4)
				53	Elekeiroz (ELEK4)
Outros / Administração	1995	2	Montreal (VEMG4)	54	Trevisa (LUXM3)
Comércio	1995	3	Mesbla (MESB4)	55	Lojas Renner (LREN3)
Construção	1996	4	Sv Engenhar (SAD4)	56	Mendes Jr (MEND3)
Outros / Curtumes	1997	5	Corbetta (CBTA4)	57	Cedro (CEDO4)
Veículos e peças	1997	6	Spsc Industrial (BFCV4)	58	Randon Part (RAPT4)
Comércio	1998	7	Lojas Arapua (LOAR4)	59	Bompreco (BPCO4)
Química	1998	8	Copas (COPA4)	60	Fertibras (FBRA4)
Eletroeletrônicos	2000	9	Sharp (SHAP4)	61	Electrolux (REPA4)
Eletroeletrônicos	2002	10	Inbrac (IBRC4)	62	Trafo (TRFO4)
				63	Springer (SPRI3)
Outros / Ind. Madeira	2003	11	Eucatex (EUCA4)	64	Fibria (FIBR3)
				65	Klabin S/A (KLBN4)
Alimentos e Bebidas	2004	12	Chapeco (CHAP4)	66	Iguacu Cafe (IGUA3)
Alimentos e Bebidas	2004	13	Parmalat (LCSA4)	67	Leco (LECO3 / LECO4)
Transporte e Serviços	2004	14	Vasp (VASP3)	68	Tam S/A (TAMM4)

“continua”

Quadro 4 “continuação”

Setor Econômico	Ano do anúncio	Nº	Empresa Insolvente	Nº	Empresa Solvente
Transporte e Serviços	2005	15	Varig Transp (VPTA4)	69	Gol (GOLL4)
Química	2005	16	Bombril (BOBR4)	70	Pronor (PNOR4)
Outros / Ind. Produtos de plástico	2005	17	Sansuy (SNSY3)	71	Evora (PTPA4)
				72	Dixie Toga (DXTG4)
Veículos e peças	2006	18	Recrusul (RCSL4)	73	Wetzel S/A (MWET4)
				74	Riosulense (RSUL4)
Siderurgia & Metalurgia	2007	19	Kepler Weber (KEPL3)	75	Tekno (TKNO4)
Alimentos e Bebidas	2007	20	Minupar (MNPR3)	76	Josapar (JOPA4)
Têxtil	2008	21	Botucatu Tex (STRP4)	77	Karsten (CTKA4)
				78	Guararapes (GUAR4)
Agroindústria e Pesca	2008	22	Agrenco (AGEN33)	79	SLC Agrícola (SLCE3)
				80	Rasip Agro (RSIP4)
				81	Renar (RNAR3)
Construção	2008	23	Const Beter (COBE3B)	82	Azevedo (AZEVE4)
Petróleo e Gás	2008	24	Pet Manguinh (RPMG4)	83	Ceg (CEGR3)
Mínerais não Metálicos	2008	25	Chiarelli (CCHI4)	84	Eternit (ETER4)
Eletroeletrônicos	2009	26	IGB S/A (IGBR3)	85	Itautec (ITEC3)

“continua”

Quadro 4 “continuação”

Setor Econômico	Ano do anúncio	Nº	Empresa Insolvente	Nº	Empresa Solvente
Têxtil	2010	27	Tex Renaux (TXRX4)	86	Le Lis Blanc (LLIS3)
				87	Alpargatas (ALPA4)
Têxtil	2010	28	Tecel S Jose (SJOS4)	88	Marisol (MRSL4)
Têxtil	2011	29	Schlosser (SCLO4)	89	Ind Cataguas (CATA4)
				90	Pettenati (PTNT4)
Têxtil	2011	30	Buettner (BUET4)	91	Cremer (CREM3)
				92	Wembley (WMBY4)
				93	Dohler (DOHL4)
Têxtil	2011	31	Fab C Renaux (FTRX4)	94	Vicunha Text (VINE3)
				95	Arezzo Co (ARZZ3)
Energia Elétrica	2012	32	Celpa (CELP3)	96	Celpe (CEPE3)
				97	Cemat (CMGR4)
				98	Celesc (CLSC4)
Outros / Comercio	2012	33	Lark Maqs (LARK4)	99	Minasmaquinas (MMAQ4)
Outros / Consultoria	2012	34	Tecnosolo (TCNO4)	100	Sondotecnica (OND3)
				101	Mills (MILS3)
Têxtil	2012	35	Teka (TEKA4)	102	Springs (SGPS3)
				103	Coteminas (CTNM4)

“continua”

Quadro 4 “conclusão”

Setor Econômico	Ano do anúncio	Nº	Empresa Insolvente	Nº	Empresa Solvente
Energia Elétrica	2012	36	Rede Energia (REDE4)	104	Tractebel (TBLE3)
				105	Energias BR (ENBR3)
Outros / Administração	2013	37	Gp Invest (GPIV33)	106	Kroton (KROT4)
Outros / Administração	2013	38	GPC Part (GPCP3)	107	Habitasul (HBTS3)
Alimentos e Bebidas	2013	39	Clarion (CLAN4)	108	Cacique (CIQU4)
Petróleo e Gás	2013	40	OGX Petroleo (OGXP3)	109	Petrobras (PETR4)
Siderurgia & Metalurgia	2013	41	Mangels Indl (MGEL4)	110	Forja Taurus (FJTA4)
Veículos e peças	2013	42	OSX Brasil (OSXB3)	111	Tupy (TUPY4)
Siderurgia & Metalurgia	2014	43	Met Duque (DUQE4)	112	Aliperti (APTI4)
Siderurgia & Metalurgia	2014	44	Lupatech (LUPA3)	113	Ferbasa (FESA4)
Outros / Outras indústrias	2014	45	Inepar (INEP4)	114	V-Agro (VAGR3)
Siderurgia & Metalurgia	2014	46	Fibam (FBMC4)	115	Metal Iguacu (MTIG4)
Mineração	2014	47	MMX Miner (MMXM3)	116	Magnesita SA (MAGG3)
Energia Elétrica	2014	48	Eneva (ENEV3)	117	AES Elpa (AELP3)
Veículos e peças	2015	49	DHB (DHBI3)	118	Plascar Part (PLAS4)
				119	Fras-Le (FRAS3)
Outros / Administração	2015	50	Ideiasnet S.A. (IDNT3)	120	Itausa (ITSA4)
Construção	2015	51	Sultepa (SULT4)	121	Lix da Cunha (LIXC4)

Fonte: Elaborado pelo autor

No que se refere à amplitude da amostra (tamanho), buscou-se um número de empresas insolventes que possibilitasse as análises de forma a não prejudicar o processo de modelagem para as técnicas abordadas. Neste sentido, para a elaboração do presente estudo, a amostra foi composta por 121 empresas, sendo 70 empresas consideradas solventes e 51 empresas insolventes – atendendo o recomendado por Hair et al. (2009, p. 236) de que deve haver no “mínimo 40 empresas” pertencentes aos dois grupos definidos a priori.

Para uma melhor compreensão das características da amostra, a Tabela 3 apresenta a distribuição das empresas amostradas por setor/subsetor. Observa-se que, em decorrência da falta de informações, para realizar a pesquisa para apenas um setor específico, buscaram-se empresas insolventes independente dos setores, o que gerou uma amostra setorialmente diversificada.

Tabela 3 Distribuição das empresas por setor de atuação

Setor/Subsetor	Insolvente		Solvente		Total	
	nº	%	nº	%	nº	%
Agroindústria e Pesca	1	1,96%	3	4,29%	4	3,31%
Alimentos e Bebidas	4	7,84%	4	5,71%	8	6,61%
Comércio	2	3,92%	2	2,86%	4	3,31%
Construção	3	5,88%	3	4,29%	6	4,96%
Eletroeletrônicos	3	5,88%	4	5,71%	7	5,79%
Energia Elétrica	3	5,88%	6	8,57%	9	7,44%
Mineração	1	1,96%	1	1,43%	2	1,65%
Minerais não Metálicos	1	1,96%	1	1,43%	2	1,65%
Outros / Administração	4	7,84%	4	5,71%	8	6,61%
Outros / Comércio	1	1,96%	1	1,43%	2	1,65%
Outros / Consultoria	1	1,96%	2	2,86%	3	2,48%
Outros / Curtumes / Têxtil	1	1,96%	1	1,43%	2	1,65%
Outros / Ind. Madeira / Papel e Celulose	1	1,96%	2	2,86%	3	2,48%
Outros / Ind. Produtos de plástico	1	1,96%	2	2,86%	3	2,48%
Outros / Outras indústrias	1	1,96%	1	1,43%	2	1,65%
Petróleo e Gás	2	3,92%	2	2,86%	4	3,31%
Química	3	5,88%	4	5,71%	7	5,79%
Siderurgia & Metalurgia	5	9,80%	5	7,14%	10	8,26%
Têxtil	7	13,73%	14	20,00%	21	17,36%
Transporte e Serviços	2	3,92%	2	2,86%	4	3,31%
Veículos e Peças	4	7,84%	6	8,57%	10	8,26%
Total	51	100%	70	100%	121	100%

Fonte: Elaborado pelo autor

Os setores mais representativos para a amostra (em negrito na TABELA 3) foram o setor de Têxtil com 7 empresas insolventes, o setor de Siderurgia & Metalurgia com 5 empresas insolventes e os setores de Alimentos e Bebidas e Veículos e Peças com 4 empresas insolventes cada. No próximo tópico, são apresentados os indicadores selecionados para representar o Modelo Fleuriet de análise financeira e o Modelo Tradicional de análise financeira.

3.3 Definição dos indicadores

Para a seleção dos indicadores do Modelo Tradicional de análise financeira, foram utilizados os indicadores que mais aparecem no levantamento realizado com trabalhos da área, conforme apresentado no tópico ‘2.2.2 A análise quantitativa do crédito’.

Já, no que diz respeito à escolha dos indicadores do Modelo Fleuriet de análise financeira, baseia-se no trabalho inicial de Fleuriet et al. (1978), passando pelas principais obras apresentadas no tópico ‘2.3 O Modelo Fleuriet’, que demonstram a importância para identificar problemas futuros de insolvência nas empresas.

A definição dos indicadores está fundamentada nas considerações de Pereira, Domínguez e Ocejo (2007), em que os autores afirmam que a evidência empírica tem apontado que a escolha de indicadores que apresentaram resultados satisfatórios em pesquisas anteriores tem elevado potencial para novas pesquisas.

O Banco de dados, contendo as contas das demonstrações contábeis para o cálculo de todos os indicadores propostos, foi elaborado com base no Economática. Empresas que apresentaram demonstrações contábeis incompletas foram excluídas da amostra.

O Quadro 5 apresenta os indicadores referentes ao Modelo Fleuriet que foram utilizados na presente pesquisa, com base no referencial levantado e nas delimitações da pesquisa.

Já o Quadro 6 apresenta os indicadores selecionados, com base no modelo de análise financeira tradicional, que foram utilizados, no presente estudo, com base no referencial levantado e nas delimitações da pesquisa.

Quadro 5 Indicadores do Modelo Fleuriet

Modelo Fleuriet			
Cód.	Indicadores	Fórmula	Autores
X1	CDG sobre Ativo	CDG / AT	Apresentados neste trabalho
X2	CDG sobre Receita Líquida	CDG / RL	
X3	NCG sobre Ativo	NCG / AT	Brito, Assaf Neto e Corrar (2009), Carvalho (2004), Minussi, Damacena e Ness Junior (2002) e Sanvicente e Minardi (1998)
X4	NCG sobre Receita Líquida	NCG / RL	
X5	Saldo de Tesouraria sobre Ativo	T / AT	Brito, Assaf Neto e Corrar (2009), Carvalho (2004), Eifert (2003), Horta (2010), Minussi, Damacena e Ness Junior (2002) e Sanvicente e Minardi (1998)
X6	Saldo de Tesouraria sobre Receita Líquida	T / RL	
X7	Passivo Financeiro sobre Ativo Circulante	PF / AC	Eifert (2003)
X8	Tipo de Estrutura Financeira	TEF	Melo e Coutinho (2007)
X9	Termômetro de liquidez - TL	$T / (NCG)$	Horta (2010) e Vieira (2008)
X10	Saldo de Tesouraria	$T=AF-PF$	Melo e Coutinho (2007)
X11	Necessidade de Capital de Giro	$NCG = AO - PO$	Melo e Coutinho (2007)
X12	Capital de Giro	$CDG = PNC - ANC$	Melo e Coutinho (2007)
X13	Endividamento financeiro	$(PF + PNCF) / AT$	Brito, Assaf Neto e Corrar (2009)

Fonte: Elaborado pelo autor

Quadro 6 Indicadores do Modelo Tradicional

Modelo Tradicional			
Cód.	Indicadores	Fórmula	Autores
X14	Capital de giro líquido	$(AC - PC) / AT$	Altman (1968), Altman, Baydia e Dias (1979), Brito, Assaf Neto e Corrar (2009) e Sanvicente e Minardi (1998)
X15	Retorno sobre o ativo	$LAJIR / AT$	Altman (1968), Altman, Baydia e Dias (1979), Brito, Assaf Neto e Corrar (2009) e Sanvicente e Minardi (1998)
X16	Patrimônio líquido dividido pelo exigível total	PL / ET	Altman, Baydia e Dias (1979), Horta (2010) e Soares e Rebouças (2015)
X17	Giro do ativo	RL / AT	Altman (1968), Altman, Baydia e Dias (1979), Brito, Assaf Neto e Corrar (2009) e Castro Junior (2003)
X18	Retorno sobre o Ativo	LL / AT	Castro Junior (2003), Eifert (2003), Horta (2010), Scarpel (2008) e Soares e Rebouças (2015)
X19	Lucros retidos sobre ativo	$(LA + RL) / AT$	Brito, Assaf Neto e Corrar (2009)
X20	Rentabilidade do Patrimônio Líquido	LL / PL	Castro Junior (2003), Brito, Assaf Neto e Corrar (2009) e Kanitz (1978)
X21	Liquidez corrente	AC / PC	Brito, Assaf Neto e Corrar (2009), Castro Junior (2003), Horta (2010), Kanitz (1978), Matias (1978) e Silva (1982)
X22	Liquidez seca	$(AC - ESTOQUES) / PC$	Brito, Assaf Neto e Corrar (2009), Horta (2010), Kanitz (1978) e Onusic et al. (2006)
X23	Liquidez geral	$(AC + RLP) / (PC + PNC)$	Brito, Assaf Neto e Corrar (2009), Horta (2010), Kanitz (1978), Onusic et al. (2006), Scarpel (2008) e Soares e Rebouças (2015)

“continua”

Quadro 6 “conclusão”

Modelo Tradicional			
Cód.	Indicadores	Fórmula	Autores
X24	Lucro operacional sobre despesas financeiras	$LAJIR / DF$	Brito, Assaf Neto e Corrar (2009), Carvalho et al. (2010), Sanvicente e Minardi (1998) e Soares e Rebouças (2015)
X25	Margem Líquida	LL / RL	Brito, Assaf Neto e Corrar (2009), Castro Junior (2003), Elizabetsky (1976), Horta (2010) e Minussi, Damascena e Ness Júnior (2002)
X26	Endividamento total	$(PC + PNC) / AT$	Brito, Assaf Neto e Corrar (2009), Horta (2010), Silva (1982) e Soares e Rebouças (2015)
X27	Indicador de estrutura	$FORNECEDOR / AT$	Matias (1978) e Silva (1982)
X28	Composição do Endividamento	$PC / (PC + PNC)$	Castro Junior (2003)
X29	Participação de Capitais de Terceiros	$(PC + PNC) / PL$	Castro Junior (2003)
X30	Imobilização do patrimônio líquido	$ATIVO FIXO / PL$	Brito, Assaf Neto e Corrar (2009), Castro Junior (2003) e Soares e Rebouças (2015)
X31	Patrimônio líquido sobre ativo	PL / AT	Brito, Assaf Neto e Corrar (2009) e Matias (1978)
X32	Estoques sobre ativo	$ESTOQUES / AT$	Brito, Assaf Neto e Corrar (2009), Elizabetsky (1976), Minussi, Damascena e Ness Júnior (2002) e Silva (1982)
X33	Liquidez imediata	$DISPONÍVEL / PC$	Brito, Assaf Neto e Corrar (2009), Castro Junior (2003), Horta (2010) e Soares e Rebouças (2015)
X34	Indicador de estrutura	$DISPONÍVEL / AT$	Matias (1978), Silva (1982), Carvalho (2004)
X35	Indicador de estrutura	$DISPONÍVEL / ANC$	Elizabetsky (1976), Silva (1982) e Soares e Rebouças (2015)

Fonte: Elaborado pelo autor

Com o propósito de facilitar a compreensão e a visualização dos indicadores no Quadro 5 e 6, as notações utilizadas para o cálculo são apresentadas de forma separada no Quadro 7.

Quadro 7 Notação das Fórmulas de Cálculo dos Indicadores

Notação			
AC	Ativo circulante	LL	Lucro líquido
ACF	Ativo circulante financeiro	NCG	Necessidade de capital de giro
ACO	Ativo circulante operacional	PC	Passivo circulante
AF	Ativo financeiro	PF	Passivo financeiro
AO	Ativo operacional	PL	Patrimônio líquido
ANC	Ativo não circulante	PO	Passivo operacional
AT	Ativo total	PNC	Passivo não circulante
CDG	Capital de giro	PNC F	Passivo não circulante financeiro
DF	Despesas financeiras	RL	Reserva de Lucros
EB	Estrutura de balanço (ordinal)	RLP	Realizável em longo prazo
ET	Exigível total	T	Saldo em tesouraria
LA	Lucros acumulados	TL	Termômetro de liquidez
LAI	Lucro antes dos juros e	RL	Receita líquida
R	imposto de renda		
LB	Lucro Bruto		

Fonte: Elaborado pelo autor

Bellovary, Giacomino e Akers (2007) enfatizam que o número de indicadores utilizados nos modelos, também, é analisado por décadas, mostrando que a média tem variado ao longo do tempo, mas continua em torno de 10 indicadores no geral. Os resultados, também, sugerem que um maior número de indicadores não garante modelos superiores de previsão. Alguns modelos com apenas dois indicadores podem apresentar precisão idêntica a modelos com 21 indicadores. Como menciona Iudícibus (2014, p. 251), “lembre-se de que os maiores analistas de investimentos, os mais afortunados homens de negócios,

não precisaram mais que de uma dezena de quocientes selecionados para auxiliá-los em suas tomadas de decisões”.

Neste sentido, um elevado número de indicadores apresenta diversos contratempos como dificuldade de manuseio e interpretação e, ainda, problemas de ordem técnica como pares de indicadores altamente correlacionados, sendo que à colinearidade entre os indicadores pode interferir de forma negativa em modelos como a análise discriminante (HAIR et al., 2009).

Diante do exposto, com intuito de realizar modelos mais parcimoniosos e identificar quais os principais indicadores econômico-financeiros podem melhor discriminar empresas solventes de empresas insolventes na análise de concessão do crédito, propõe-se utilizar de técnicas como o *stepwise*⁴, que auxiliam na eliminação de indicadores menos significativos (com base em uma estatística F). Seguindo os passos de Soares e Rebouças (2015), outra possibilidade para se eliminar indicadores é por meio da análise fatorial. Segundo Corrar et al. (2014), considera-se o pressuposto de que os indicadores são independentes uns dos outros e, neste sentido a análise fatorial criará uma dimensão para cada variável de forma independente. Entretanto, se houverem relações de dependência entre os indicadores as dimensões conterão mais de uma variável.

Corrar et al. (2014) observam que isso ocorre em razão da multicolinearidade, pois a análise fatorial agrupa as dimensões com indicadores altamente correlacionados. Soares e Rebouças (2015) afirmam que, tendo a análise fatorial encontrado fatores (dimensões) com mais de uma variável, é

⁴ Método “passo a passo” (*stepwise*): este método é uma fusão do *backward* (passo atrás) e do *forward* (passo a frente), ou seja, após cada etapa de incorporação de uma variável, tem-se uma etapa em que uma das variáveis já selecionadas pode ser descartada. Este procedimento chega ao fim, quando nenhuma variável é incluída ou descartada (CHARNET et al., 2008).

possível retirar a variável com maior escore (poder discriminante) e utilizá-la, posteriormente, nas técnicas de classificação.

Buscando-se atender o objetivo geral de verificar se o Modelo Fleuriet contribui para discriminação das empresas, na análise de concessão de crédito, propõe-se realizar para cada técnica empregada (análise discriminante, regressão logística e redes neurais artificiais) uma classificação contendo os indicadores do Modelo Tradicional de análise financeira juntamente com os indicadores do Modelo proposto por Fleuriet.

De posse dos modelos, será possível verificar, por meio da curva ROC, qual das técnicas empregadas (análise discriminante, regressão logística e redes neurais artificiais) apresenta melhor resultado. Também será possível verificar quais foram os indicadores que mais contribuíram para análise da concessão de crédito por meio da análise da solvência empresarial.

Para o desenvolvimento dos modelos, utilizou-se o *software* SPSS 20.0 (*Statistical Package for Social Sciences*). Corrar et al. (2014) e Field (2013) observam que é preciso atenção para a presença de *outliers*, os quais prejudicam fortemente as análises. Segundo os autores, devem-se executar testes para identificar os *outliers* e, quando encontrados, optar por transformar os dados, quando for o caso, ou eliminá-los da amostra antes do início da modelagem.

No presente estudo, optou-se por eliminar os *outliers*, utilizando a técnica de *winsorização*⁵. O processo auxiliou os níveis de Curtose e Assimetria para os indicadores estudados. Nas áreas de Finanças e Economia, a *winsorização* tem sido bastante utilizada de forma a controlar eventuais *outliers*

⁵ A *winsorização* é um procedimento que apara os valores extremos de uma variável (abaixo ou acima dos percentuais mínimos e máximos definidos), substituindo-os pelos valores menores e maiores remanescentes dentro da distribuição. Esse processo busca estabilizar a variância de uma população normal a partir de uma distribuição que possua pequenas proporções de valores anormais, sem que seja necessário descartá-los da amostra (HASTINGS JUNIOR et al., 1947; LOGAN, 2011).

(ARTIACH et al., 2010; DURNEV; KIM, 2005; SILVEIRA; BARROS; FAMÁ, 2006).

No próximo tópico, são apresentados a estatística descritiva, os resultados da análise fatorial para definição dos indicadores, os resultados encontrados para análise discriminante, regressão logística e redes neurais artificiais, a comparação dessas técnicas assim como a discussão dos índices mais relevantes encontrados para análise do risco de crédito.

4 RESULTADOS E DISCUSSÃO

Nesse tópico, são apresentados os resultados encontrados, tanto no que diz respeito aos modelos gerados quanto ao desempenho do Modelo Fleuriet para análise da solvência empresarial. Primeiramente busca-se, por meio da análise da estatística descritiva, compreender melhor as características da amostra utilizada. Pelo fato de a amostra ser representada por dois grupos, empresas solventes (0) e empresas insolventes (1), além de descrever a amostra como um todo, buscou-se dar ênfase às características individuais de cada grupo, sendo esse ponto o mais relevante para o presente estudo.

Na Tabela 4, apresenta-se a estatística descritiva para a amostra e seus subgrupos (solventes = 0, insolventes = 1), assim como os valores Assimetria e Curtose para cada indicador individualmente. Os valores de significância, apresentados para Assimetria e Curtose, foram obtidos baseados nos valores padronizados, por meio dos escores-z, obtidos pela subtração do valor em questão da média da distribuição e dividindo o resultado pelo desvio padrão da distribuição (Ex. $Z_{Assimetria} = \frac{S-\bar{X}}{\sigma_{Assimetria}}$ e $Z_{Curtose} = \frac{K-\bar{X}}{\sigma_{Curtose}}$, os valores da significância são definidos ao se observar os valores padronizados como valores absolutos, ou seja, $|x| > 1,96$ é significativo a $p > 0,05$, $|x| > 2,58$ é significativo a $p > 0,01$ e $|x| > 3,29$ é significativo a $p > 0,001$) (FIELD, 2013).

Algumas considerações podem ser feitas, inicialmente, por meio da Tabela 4. Primeiramente, observa-se que a medida do grupo solvente e insolvente é diferente para maioria dos indicadores pesquisados e que os níveis de significância, para Assimetria e Curtose, apresentam valores satisfatórios para muitos dos valores totais da amostra. Um gráfico com o histograma individual para cada indicador definido por subgrupos (solventes e insolventes) pode ser visualizado no APÊNDICE A.

Tabela 4 Estatística Descritiva dos Indicadores

Descritivos		N	Média	Desvio Padrão	Mínimo	Máximo	Assimetria		Curtose	
							Estatística	Sig.	Estatística	Sig.
X1) CDG / AT	1	51	-0,302	0,381	-1,009	0,266	-0,806		-0,502	
	0	70	0,166	0,189	-0,213	0,728	0,312		-0,128	
	Total	121	-0,031	0,367	-1,009	0,728	-1,183	0,010	1,418	0,001
X2) CDG / RL	1	51	-0,505	1,274	-2,621	2,980	0,721		1,765	
	0	70	0,251	0,450	-0,929	2,980	3,195		19,626	
	Total	121	-0,068	0,966	-2,621	2,980	-0,038	n.s.	3,377	0,001
X3) NCG / AT	1	51	-0,077	0,257	-0,659	0,365	-0,945		0,287	
	0	70	0,175	0,132	-0,031	0,519	0,478		-0,388	
	Total	121	0,069	0,231	-0,659	0,519	-1,264	0,001	2,316	0,001
X4) NCG / RL	1	51	-0,114	0,439	-0,998	0,874	-0,153		-0,013	
	0	70	0,258	0,211	-0,060	0,864	0,998		0,866	
	Total	121	0,101	0,374	-0,998	0,874	-0,811	0,050	1,373	0,001
X5) T / AT	1	51	-0,231	0,261	-0,901	0,200	-0,897		0,565	
	0	70	0,007	0,148	-0,322	0,465	0,202		0,849	
	Total	121	-0,094	0,235	-0,901	0,465	-1,144	0,001	2,262	0,001
X6) T / RL	1	51	-0,547	0,925	-2,649	0,997	-0,955		0,678	
	0	70	-0,005	0,315	-1,499	0,994	-1,381		8,089	
	Total	121	-0,233	0,697	-2,649	0,997	-1,890	0,050	4,481	0,001
X7) PF / AC	1	51	1,378	1,029	0,057	3,785	1,134		0,151	
	0	70	0,442	0,329	0,031	1,726	1,650		3,145	
	Total	121	0,837	0,848	0,031	3,785	2,007	n.s.	3,697	0,001

"continua"

Tabela 4 “continuação”

Descritivos		N	Média	Desvio Padrão	Mínimo	Máximo	Assimetria		Curtose	
							Estatística	Sig.	Estatística	Sig.
X8) TEF = Estrutura	1	51	4,294	1,082	1,000	6,000	-1,017		0,903	
	0	70	2,614	0,873	1,000	5,000	0,445		-0,273	
	Total	121	3,322	1,273	1,000	6,000	0,160	0,050	-1,040	0,001
X9) TL = T / (NCG)	1	51	-5,871	9,580	-26,496	6,996	-1,411		0,505	
	0	70	0,254	1,986	-5,328	6,986	1,022		3,768	
	Total	121	-2,328	7,052	-26,496	6,996	-2,581	n.s.	6,150	n.s.
X10) T = AF – PF	1	51	-246350	549517	-1557441	1422049	0,048		3,366	
	0	70	20658	423002	-1557441	1422049	0,341		5,487	
	Total	121	-91883	496220	-1557441	1422049	-0,056	n.s.	3,808	n.s.
X11) NCG = AO – PO	1	51	23671	196769	-286261	784853	1,971		6,037	
	0	70	251798	283467	-167550	905259	1,203		0,471	
	Total	121	155645	274100	-286261	905259	1,372	n.s.	1,490	n.s.
X12) CDG = PNC – ANC	1	51	-209052	547758	-1466833	1465732	0,179		3,371	
	0	70	201269	443412	-1466833	1465732	0,313		3,819	
	Total	121	28324	528644	-1466833	1465732	-0,041	n.s.	2,627	n.s.
X13) (PF + PNCF) / AT	1	51	0,627	0,464	0,117	1,757	1,505		1,314	
	0	70	0,281	0,162	0,020	0,720	0,455		-0,275	
	Total	121	0,427	0,366	0,020	1,757	2,276	0,001	5,680	0,001
X14) (AC – PC) / AT	1	51	-0,395	0,529	-1,495	0,251	-1,245		0,252	
	0	70	0,154	0,189	-0,257	0,720	0,191		0,063	
	Total	121	-0,077	0,460	-1,495	0,720	-1,848	0,001	3,508	0,001

“continua”

Tabela 4 “continuação”

Descritivos		N	Média	Desvio Padrão	Mínimo	Máximo	Assimetria		Curtose	
							Estatística	Sig.	Estatística	Sig.
X15) LAJIR / AT	1	51	-0,090	0,164	-0,416	0,356	-0,469		0,566	
	0	70	0,067	0,097	-0,376	0,346	-1,220		6,195	
	Total	121	0,001	0,151	-0,416	0,356	-1,065	0,001	1,652	0,001
X16) PL / ET	1	51	0,120	0,711	-0,863	3,832	2,693		14,097	
	0	70	1,247	0,992	-0,199	3,852	1,353		1,347	
	Total	121	0,772	1,043	-0,863	3,852	1,311	n.s.	1,997	n.s.
X17) RL / AT	1	51	0,675	0,481	-0,008	1,885	0,687		-0,089	
	0	70	0,793	0,425	0,033	1,884	0,428		-0,275	
	Total	121	0,743	0,451	-0,008	1,885	0,494	n.s.	-0,288	0,050
X18) LL / AT	1	51	-0,178	0,190	-0,526	0,237	-0,597		-0,478	
	0	70	0,030	0,080	-0,320	0,241	-1,104		4,971	
	Total	121	-0,057	0,172	-0,526	0,241	-1,367	0,001	1,505	0,001
X19) (LA + RL) / AT	1	51	-0,712	0,920	-2,578	0,310	-1,209		-0,081	
	0	70	0,052	0,211	-0,868	0,559	-2,141		7,506	
	Total	121	-0,270	0,723	-2,578	0,559	-2,288	0,010	4,403	0,001
X20) LL / PL	1	51	-0,312	0,743	-1,857	0,674	-0,941		-0,143	
	0	70	0,052	0,213	-1,010	0,675	-1,895		9,696	
	Total	121	-0,101	0,537	-1,857	0,675	-1,967	0,001	3,824	0,001
X21) AC / PC	1	51	0,655	0,538	0,007	2,994	2,006		6,399	
	0	70	1,671	0,767	0,391	3,598	0,612		-0,199	
	Total	121	1,243	0,844	0,007	3,598	0,778	n.s.	0,017	n.s.

“continua”

Tabela 4 “continuação”

Descritivos	N	Média	Desvio Padrão	Mínimo	Máximo	Assimetria		Curtose		
						Estatística	Sig.	Estatística	Sig.	
X22) (AC – ESTOQUES) / PC	1	51	0,494	0,459	0,007	2,598	2,448		8,735	
	0	70	1,236	0,603	0,333	2,600	0,721		0,010	
	Total	121	0,923	0,657	0,007	2,600	0,896	n.s.	0,312	n.s.
X23) (AC + RLP) / (PC + PNC)	1	51	0,591	0,401	0,027	2,006	1,056		1,824	
	0	70	1,182	0,659	0,296	2,744	1,003		0,361	
	Total	121	0,933	0,635	0,027	2,744	1,185	n.s.	1,245	n.s.
X24) LAJIR / DF	1	51	-0,566	1,473	-5,656	4,186	-0,913		6,041	
	0	70	1,846	2,609	-5,657	7,275	0,183		1,292	
	Total	121	0,829	2,500	-5,657	7,275	0,537	n.s.	1,640	n.s.
X25) LL / RL	1	51	-0,361	0,455	-1,359	0,538	-0,793		0,463	
	0	70	0,040	0,154	-0,455	0,537	-0,077		3,883	
	Total	121	-0,129	0,374	-1,359	0,538	-1,671	0,001	3,375	0,001
X26) (PC + PNC) / AT	1	51	1,272	0,869	0,143	2,984	1,171		-0,219	
	0	70	0,518	0,209	0,118	1,249	0,828		1,969	
	Total	121	0,836	0,692	0,118	2,984	2,194	0,050	4,048	0,001
X27) FORNECEDOR / AT	1	51	0,130	0,097	0,001	0,349	0,898		-0,319	
	0	70	0,068	0,059	0,000	0,309	1,824		4,219	
	Total	121	0,094	0,083	0,000	0,349	1,447	0,001	1,495	0,001
X28) PC / (PC + PNC)	1	51	0,623	0,225	0,129	0,986	-0,316		-0,738	
	0	70	0,569	0,216	0,116	0,999	0,213		-0,543	
	Total	121	0,592	0,220	0,116	0,999	-0,008	0,010	-0,760	0,001

“continua”

Tabela 4 “conclusão”

Descritivos		N	Média	Desvio Padrão	Mínimo	Máximo	Assimetria		Curtose	
							Estatística	Sig.	Estatística	Sig.
X29) (PC + PNC) / PL	1	51	1,847	3,526	-5,022	7,758	0,133		-0,916	
	0	70	1,177	1,701	-5,023	7,748	0,211		8,505	
	Total	121	1,459	2,637	-5,023	7,758	0,419	n.s.	1,046	n.s.
X30) ATIVO FIXO / PL	1	51	1,231	1,736	-1,860	4,536	0,373		-0,574	
	0	70	0,998	0,960	-1,861	4,536	0,912		5,672	
	Total	121	1,096	1,341	-1,861	4,536	0,667	n.s.	1,188	n.s.
X31) PL / AT	1	51	-0,259	0,842	-1,870	0,857	-1,138		-0,306	
	0	70	0,480	0,207	-0,249	0,882	-0,874		2,004	
	Total	121	0,169	0,674	-1,870	0,882	-2,150	0,001	3,838	0,001
X32) ESTOQUES / AT	1	51	0,079	0,072	0,000	0,306	1,095		1,251	
	0	70	0,113	0,084	0,000	0,293	0,301		-0,949	
	Total	121	0,099	0,081	0,000	0,306	0,599	0,001	-0,480	0,001
X33) DISPONÍVEL / PC	1	51	0,083	0,198	0,000	1,225	4,537		23,256	
	0	70	0,338	0,364	0,001	1,226	1,161		0,358	
	Total	121	0,230	0,329	0,000	1,226	1,766	0,001	2,295	0,001
X34) DISPONÍVEL / AT	1	51	0,032	0,048	0,000	0,207	2,434		6,229	
	0	70	0,072	0,070	0,001	0,208	0,854		-0,620	
	Total	121	0,055	0,064	0,000	0,208	1,303	0,001	0,516	0,001
X35) DISPONÍVEL / ANC	1	51	0,087	0,147	0,000	0,875	3,500		16,085	
	0	70	0,226	0,267	0,001	0,885	1,378		0,875	
	Total	121	0,167	0,234	0,000	0,885	1,907	0,001	2,986	0,001

n.s.: não significativo

Fonte: Dados da pesquisa

Para verificar se os indicadores apresentam realmente diferenças estatísticas significativas, para discriminar os grupos solventes e insolventes, foi realizado o Teste da ANOVA de um fator (*One-Way*) para comparar as médias individuais dos grupos e verificar o poder de discriminação de cada indicador.

Um dos pressupostos da ANOVA é a hipótese nula de homogeneidade de variância (grupos têm variâncias iguais), que pode ser medida, por meio do teste de Levene, que apresenta valores não significativos (Sig. > 0,05) para validar a igualdade de variâncias dos grupos (este teste não depende do pressuposto de normalidade). Como pode ser observado na Tabela 5, a estatística de Levene, para testar a igualdade de variâncias dos grupos, apresentou-se significativa (Sig. < 0,05) para quase todos os indicadores, sendo assim, pode-se afirmar que as variâncias dos grupos são significativamente diferentes e, por isso, violou-se um dos pressupostos do modelo (FIELD, 2013).

O teste Z da ANOVA pontua que existe diferença entre os grupos e, quando as variâncias não são iguais e os grupos possuem tamanhos desiguais (como no presente caso), é preciso uma estatística mais robusta, como o Teste de Brown-Forsythe e Welch, para medir as médias dos grupos. Em substituição ao teste Z da ANOVA, utiliza-se a estatística Brown-Forsythe e Welch que são preferíveis à estatística Z quando a suposição de variâncias iguais não se sustenta.

A Tabela 5 apresenta a estatística Brown-Forsythe e Welch, validando o processo da ANOVA para a maioria dos indicadores, isto é, os indicadores possuem médias diferentes entre os grupos, o que possibilita, estatisticamente, criar regras para identificar empresas solventes e empresas insolventes.

Tabela 5 ANOVA de um fator (One-Way)

ANOVA			Levene ¹		Brown-Forsythe ²		Welch ²	
	F	Sig.	Estatística ^a	Sig.	Estatística ^a	Sig.	Estatística ^a	Sig.
X1) CDG / AT	79,110	0,000	23,240	0,000	65,264	0,000	65,264	0,000
X2) CDG / RL	21,109	0,000	27,576	0,000	16,473	0,000	16,473	0,000
X3) NCG / AT	49,228	0,000	16,205	0,000	40,930	0,000	40,930	0,000
X4) NCG / RL	38,266	0,000	22,139	0,000	31,374	0,000	31,374	0,000
X5) T / AT	40,414	0,000	9,967	0,002	34,334	0,000	34,334	0,000
X6) T / RL	20,785	0,000	36,348	0,000	16,145	0,000	16,145	0,000
X7) PF / AC	50,849	0,000	50,265	0,000	39,216	0,000	39,216	0,000
X8) TEF = Estrutura	89,117	0,000	1,459	0,230	83,331	0,000	83,331	0,000
X9) TL = T / (NCG)	27,091	0,000	63,448	0,000	20,210	0,000	20,210	0,000
X10) T = AF – PF	9,121	0,003	3,174	0,077	8,410	0,005	8,410	0,005
X11) NCG = AO – PO	24,427	0,000	11,701	0,001	27,289	0,000	27,289	0,000
X12) CDG = PNC – ANC	20,692	0,000	1,019	0,315	19,370	0,000	19,370	0,000
X13) (PF + PNCF) / AT	33,325	0,000	26,321	0,000	25,976	0,000	25,976	0,000
X14) (AC – PC) / AT	64,170	0,000	35,999	0,000	50,146	0,000	50,146	0,000
X15) LAJIR / AT	43,138	0,000	11,438	0,001	37,036	0,000	37,036	0,000
X16) PL / ET	47,895	0,000	6,792	0,010	53,028	0,000	53,028	0,000
X17) RL / AT	2,034	0,156	0,464	0,497	1,957	0,165	1,957	0,165
X18) LL / AT	67,883	0,000	46,527	0,000	54,342	0,000	54,342	0,000
X19) (LA + RL) / AT	45,193	0,000	88,573	0,000	33,908	0,000	33,908	0,000

“continua”

Tabela 5 “conclusão”

ANOVA			Levene ¹		Brown-Forsythe ²		Welch ²	
	F	Sig.	Estatística ^a	Sig.	Estatística ^a	Sig.	Estatística ^a	Sig.
X19) (LA + RL) / AT	45,193	0,000	88,573	0,000	33,908	0,000	33,908	0,000
X20) LL / PL	15,177	0,000	59,983	0,000	11,579	0,001	11,579	0,001
X21) AC / PC	65,897	0,000	10,855	0,001	73,408	0,000	73,408	0,000
X22) (AC – ESTOQUES) / PC	54,241	0,000	6,365	0,013	59,005	0,000	59,005	0,000
X23) (AC + RLP)/(PC + PNC)	32,301	0,000	9,870	0,002	37,379	0,000	37,379	0,000
X24) LAJIR / DF	35,309	0,000	12,235	0,001	41,595	0,000	41,595	0,000
X25) LL / RL	47,223	0,000	48,160	0,000	36,670	0,000	36,670	0,000
X26) (PC + PNC) / AT	48,940	0,000	82,539	0,000	36,827	0,000	36,827	0,000
X27) FORNECEDOR / AT	18,553	0,000	17,635	0,000	16,053	0,000	16,053	0,000
X28) PC / (PC + PNC)	1,780	0,185	0,376	0,541	1,757	0,188	1,757	0,188
X29) (PC + PNC) / PL	1,920	0,168	37,199	0,000	1,575	0,214	1,575	0,214
X30) ATIVO FIXO / PL	0,885	0,349	26,121	0,000	0,747	0,390	0,747	0,390
X31) PL / AT	49,998	0,000	83,509	0,000	37,685	0,000	37,685	0,000
X32) ESTOQUES / AT	5,368	0,022	3,086	0,082	5,641	0,019	5,641	0,019
X33) DISPONÍVEL / PC	20,571	0,000	26,619	0,000	24,431	0,000	24,431	0,000
X34) DISPONÍVEL / AT	12,573	0,001	13,812	0,000	14,128	0,000	14,128	0,000
X35) DISPONÍVEL / ANC	11,301	0,001	18,241	0,000	13,383	0,000	13,383	0,000

¹Teste de Homogeneidade de Variâncias

²Testes Robustos de Igualdade de Médias

Fonte: Dados da pesquisa

Como se obteve uma estatística positiva a respeito dos indicadores, pode-se dar continuidade às análises para a amostra. No próximo tópico, foi realizada a Análise Fatorial com intuito de verificar os agrupamentos possíveis para os indicadores e, também, quais indicadores são mais representativos para cada fator encontrado. Esse procedimento, como discutido na metodologia, procura definir grupos de indicadores que possam ser representativos na criação dos modelos de análise de crédito propostos. Já o modelo de análise discriminante será apresentado no tópico 4.2, o modelo de regressão logística no tópico 4.3 e o modelo de redes neurais artificiais no tópico 4.4.

4.1 Análise Fatorial

Como opção para definição dos indicadores, foi realizada uma análise fatorial visando verificar entre os fatores encontrados quais indicadores seriam mais representativos do conjunto de dados. Esse procedimento visa criar um maior número de opções para os agrupamentos de indicadores serem testados nos modelos desenvolvidos.

Para a primeira fatorial realizada (FATORIAL 01), foram encontrados os seguintes resultados: para os Testes de KMO (Kaiser-Meyer-Olkin), a medida de adequação de amostragem foi de 0,824 e o teste de Esfericidade de Bartlett obteve p valor = 0,000 (significativo a 0,05). Os valores para o KMO são satisfatórios, segundo o critério apresentado por Field (2013): mínimo aceitável = 0,5; entre 0,5 e 0,7 = medíocres; entre 0,7 e 0,8 = bons; entre 0,8 e 0,9 = ótimos e acima de 0,9 excelentes. Já o teste de Esfericidade de Bartlett pressupõe que quanto mais próximo de zero (0,000) for o nível de significância, maior será a adequação da análise fatorial ao conjunto de dados (Sig. < 0,05)

(HAIR et al., 2009). Assim, acredita-se que a análise dos fatores é apropriada para esse conjunto de dados.

A Tabela 6 apresenta as comunalidades para cada indicador. Hair et al. (2009) afirmam que os valores, acima de 0,80, são bastante razoáveis, já os valores superiores a 0,9 indicam que cada indicador sozinho poderia representar um único fator, por causa de seu alto poder explicativo em relação a todos os outros indicadores, o que se apresenta como mais um ponto positivo na pesquisa. Segundo os autores, as comunalidades representam a quantia de variância explicada pela solução fatorial para cada indicador presente na análise.

Tabela 6 Comunalidades FATORIAL 01

Indicador	Inicial	Extração	Indicador	Inicial	Extração
X1) CDG / AT	1,000	0,93	X19) (LA + RL) / AT	1,000	0,91
X2) CDG / RL	1,000	0,63	X20) LL / PL	1,000	0,66
X3) NCG / AT	1,000	0,87	X21) AC / PC	1,000	0,89
X4) NCG / RL	1,000	0,75	X22) (AC – ESTOQUES) / PC	1,000	0,86
X5) T / AT	1,000	0,89	X23) (AC + RLP) / (PC + PNC)	1,000	0,87
X6) T / RL	1,000	0,78	X24) LAJIR / DF	1,000	0,69
X7) PF / AC	1,000	0,89	X25) LL / RL	1,000	0,76
X8) TEF = Estrutura	1,000	0,71	X26) (PC + PNC) / AT	1,000	0,94
X9) TL = T / (NCG)	1,000	0,49	X27) FORNECEDOR / AT	1,000	0,75
X10) T = AF – PF	1,000	0,80	X28) PC / (PC + PNC)	1,000	0,80
X11) NCG = AO – PO	1,000	0,52	X29) (PC + PNC) / PL	1,000	0,86
X12) CDG = PNC – ANC	1,000	0,81	X30) ATIVO FIXO / PL	1,000	0,83
X13) (PF + PNCF) / AT	1,000	0,78	X31) PL / AT	1,000	0,94
X14) (AC – PC) / AT	1,000	0,91	X32) ESTOQUES / AT	1,000	0,62
X15) LAJIR / AT	1,000	0,80	X33) DISPONÍVEL / PC	1,000	0,90
X16) PL / ET	1,000	0,77	X34) DISPONÍVEL / AT	1,000	0,88
X17) RL / AT	1,000	0,70	X35) DISPONÍVEL / ANC	1,000	0,86
X18) LL / AT	1,000	0,89			

Método de Extração: Análise de Componente Principal

Fonte: Dados da pesquisa

Na análise fatorial, utilizou-se a seleção automática, para definir o número de fatores gerados, a técnica retornou sete fatores com grau de poder explicativo de, aproximadamente, 80%, da variância total dos dados originais (TABELA, 7).

Tabela 7 Variância total explicada FATORIAL 01

Componente	Valores próprios iniciais			Somadas de extração de carregamentos ao quadrado			Somadas rotativas de carregamentos ao quadrado		
	Total	% de variância	% cumulativa	Total	% de variância	% cumulativa	Total	% de variância	% cumulativa
1	14,80	42,29	42,29	14,80	42,29	42,29	9,02	25,79	25,79
2	3,66	10,46	52,74	3,66	10,46	52,74	4,71	13,45	39,24
3	2,44	6,97	59,71	2,44	6,97	59,71	4,11	11,75	50,99
4	1,97	5,62	65,33	1,97	5,62	65,33	3,62	10,35	61,34
5	1,90	5,44	70,77	1,90	5,44	70,77	2,78	7,93	69,28
6	1,82	5,21	75,97	1,82	5,21	75,97	1,97	5,62	74,90
7	1,34	3,83	79,80	1,34	3,83	79,80	1,72	4,91	79,80
⋮	⋮	⋮	⋮						

Método de Extração: Análise de Componente Principal

Fonte: Dados da pesquisa

Dando prosseguimento, pode-se apresentar a matriz de componente rotativa obtida, por meio da rotação do método Varimax, que permite uma classificação mais precisa (CORRAR et al., 2014). Para tornar a interpretação mais clara, observa-se que, quando a correlação do indicador-fator é próxima de +1 ou -1, há uma associação positiva ou negativa entre o indicador e o fator, por outro lado, quando a correlação é próxima de 0, ocorre uma falta de associação. Desta forma, na Tabela 8, ficam evidentes quais indicadores irão compor cada fator. Por ordem de importância por componente, os indicadores foram: Retorno sobre o Ativo (X18- LL / AT); Saldo de Tesouraria (X10- $T = AF - PF$); Indicador de estrutura (X34- $DISPONÍVEL / AT$); Necessidade de Capital de Giro sobre Receita líquida (X4- NCG / RL); Participação de Capitais de Terceiros (X29- $(PC + PNC) / PL$); Giro do ativo (X17- RL / AT) e Composição do Endividamento (X28- $PC / (PC + PNC)$).

Tabela 8 Matriz de componente rotativa FATORIAL 01

Matriz de componente rotativa ^a	Componente		Matriz de componente rotativa ^a	Componente				
	1	2		3	4	5	6	7
X18) LL / AT	0,91		X34) DISPONÍVEL / AT	0,91				
X19) (LA + RL) / AT	0,84		X35) DISPONÍVEL / ANC	0,87				
X15) LAJIR / AT	0,83		X33) DISPONÍVEL / PC	0,86				
X31) PL / AT	0,81		X22) (AC – ESTOQUES) / PC	0,59				
X5) T / AT	0,72		X21) AC / PC	0,52				
X14) (AC – PC) / AT	0,72		X4) NCG / RL		0,81			
X1) CDG / AT	0,69		X3) NCG / AT		0,75			
X25) LL / RL	0,68		X11) NCG = AO – PO		0,68			
X16) PL / ET	0,59		X32) ESTOQUES / AT		0,58			
X24) LAJIR / DF	0,58		X29) (PC + PNC) / PL			0,89		
X7) PF / AC	-0,66		X30) ATIVO FIXO / PL			0,83		
X13) (PF + PNC) / AT	-0,79		X20) LL / PL			-0,78		
X26) (PC + PNC) / AT	-0,82		X17) RL / AT				0,81	
X10) T = AF – PF		0,87	X27) FORNECEDOR / AT				0,64	
X12) CDG = PNC – ANC		0,84	X28) PC / (PC + PNC)					0,82
X6) T / RL		0,65	X23) (AC + RLP) / (PC + PNC)					0,50
X9) TL = T / (NCG)		0,61						
X2) CDG / RL		0,59						
X8) TEF = Estrutura		-0,50						

Método de Extração: Análise de Componente Principal.

Método de Rotação: Varimax com Normalização de Kaiser.

a. Rotação convergida em 11 iterações.

Fonte: Dados da pesquisa

Para o apontamento do primeiro grupo com 7 indicadores, a fatorial se mostrou satisfatória. Contudo, ao se analisar a Matriz de Correlação anti-imagem (APÊNDICE B) e a Tabela de Comunalidades, observou-se a possibilidade de melhorar a acurácia da fatorial, por meio da exclusão de alguns indicadores, ou seja, a partir da análise da diagonal principal da matriz Anti-imagem pode-se ver o índice de Medida de Adequação de Amostra (*Measure of Sampling Adequacy* – MSA). Observa-se, entretanto, que esse valor varia entre 0 e 1 e que podem ser considerados: acima de 0,8 ótimo; acima 0,7 bom; acima 0,6 regular; acima 0,5 ruim e abaixo de 0,5 inaceitável. Ou seja, valores inferiores a 0,05 são considerados insignificantes para a análise e podem ser retirados dela (HAIR et al., 2009).

Neste sentido, depois de alguns testes consecutivos, foi possível encontrar uma fatorial com melhor acurácia para a presente amostra. Para a Segunda Fatorial (FATORIAL 02), o grupo de indicadores foi reduzido de 35 indicadores para 28 indicadores, pela exclusão dos indicadores que apresentaram valores inferiores a 0,05 na diagonal principal da matriz Anti-imagem: Termômetro de Liquidez (X9- TL = T / (|NCG|)); Necessidade de Capital de Giro (X11- NCG = AO – PO); Giro do ativo (X17- RL / AT); Rentabilidade do Patrimônio Líquido (X20- LL / PL); Indicador de estrutura (X27- FORNECEDOR / AT); Composição do Endividamento (X28- PC / (PC + PNC)) e Estoques sobre ativo (X32- ESTOQUES / AT).

O teste de KMO (Kaiser-Meyer-Olkin), que representa o grau de explicação dos indicadores pelos fatores encontrados, apresentou resultado de 0,853, um pouco maior que o anterior que era de 0,824 (o que é considerado ótimo já que os dois casos estão na faixa de 0,8 a 0,9). O teste de Esfericidade de Bartlett obteve p valor = 0,000 (significativo a 0,05).

A Matriz de Correlação anti-imagem, para a Segunda Fatorial apresentada no APÊNDICE B, traz os valores do MSA individual de cada

indicador. Apesar de que, nesse modelo, os indicadores X29 e X30 apresentarem valores menores do que 0,5, a exclusão dos mesmos não melhorou os níveis de significância da fatorial. Diante disso, optou-se por deixá-los no modelo.

Na Tabela 9, as comunalidades com valores superiores ($< 0,9$) e que podem representar um único fator tornaram-se mais evidentes, o que se apresenta como mais um ponto positivo para a segunda fatorial.

Tabela 9 Comunalidades FATORIAL 02

Indicador	Inicial	Extração	Indicador	Inicial	Extração
X1) CDG / AT	1,00	0,93	X18) LL / AT	1,00	0,91
X2) CDG / RL	1,00	0,80	X19) (LA + RL) / AT	1,00	0,92
X3) NCG / AT	1,00	0,81	X21) AC / PC	1,00	0,89
X4) NCG / RL	1,00	0,90	X22) (AC – ESTOQUES) / PC	1,00	0,87
X5) T / AT	1,00	0,87	X23) (AC + RLP) / (PC + PNC)	1,00	0,78
X6) T / RL	1,00	0,82	X24) LAJIR / DF	1,00	0,75
X7) PF / AC	1,00	0,86	X25) LL / RL	1,00	0,84
X8) TEF = Estrutura	1,00	0,68	X26) (PC + PNC) / AT	1,00	0,94
X10) T = AF – PF	1,00	0,86	X29) (PC + PNC) / PL	1,00	0,88
X12) CDG = PNC – ANC	1,00	0,82	X30) ATIVO FIXO / PL	1,00	0,88
X13) (PF + PNCF) / AT	1,00	0,79	X31) PL / AT	1,00	0,94
X14) (AC – PC) / AT	1,00	0,91	X33) DISPONÍVEL / PC	1,00	0,87
X15) LAJIR / AT	1,00	0,82	X34) DISPONÍVEL / AT	1,00	0,89
X16) PL / ET	1,00	0,72	X35) DISPONÍVEL / ANC	1,00	0,83

Método de Extração: Análise de Componente Principal

Fonte: Dados da pesquisa

Na Tabela 10, da Variância total explicada, observa-se que o número de fatores calculados na análise fatorial caiu de 7 para 6. Contudo, o poder e explicação do modelo subiu de 80% para, aproximadamente, 85%, da variância total dos dados originais.

Tabela 10 Variância total explicada FATORIAL 02

Componente	Valores próprios iniciais			Somadas de extração de carregamentos ao quadrado			Somadas rotativas de carregamentos ao quadrado		
	Total	% de variância	% cumulativa	Total	% de variância	% cumulativa	Total	% de variância	% cumulativa
1	14,20	50,72	50,72	14,20	50,72	50,72	7,75	27,69	27,69
2	3,24	11,57	62,29	3,24	11,57	62,29	4,23	15,10	42,79
3	1,96	7,01	69,30	1,96	7,01	69,30	3,88	13,87	56,65
4	1,75	6,24	75,53	1,75	6,24	75,53	3,01	10,75	67,41
5	1,48	5,29	80,83	1,48	5,29	80,83	2,65	9,47	76,88
6	1,16	4,13	84,96	1,16	4,13	84,96	2,26	8,08	84,96
⋮	⋮	⋮	⋮						

Método de Extração: Análise de Componente Principal

Fonte: Dados da pesquisa

Atingindo este percentual de 85%, acredita-se ter encontrado uma Análise Fatorial capaz de representar os indicadores econômico-financeiros na pesquisa, por meio de seis fatores. Portanto, faz-se necessária a interpretação de quais indicadores irão compor cada um dos fatores específicos, por meio da Matriz de Componente Rotativa, como pode ser visto na Tabela 11.

Tabela 11 Matriz de componente rotativa FATORIAL 02

Matriz de componente rotativa ^a	Componente		Matriz de componente rotativa ^a	Componente			
	1	2		3	4	5	6
X31) PL / AT	0,890		X10) T = AF – PF	0,881			
X26) (PC + PNC) / AT	-0,889		X12) CDG = PNC – ANC	0,828			
X19) (LA + RL) / AT	0,832		X6) T / RL	0,695			
X13) (PF + PNCF) / AT	-0,797		X8) TEF = Estrutura	-0,445			
X14) (AC – PC) / AT	0,738		X25) LL / RL		0,836		
X18) LL / AT	0,735		X15) LAJIR / AT		0,723		
X16) PL / ET	0,707		X24) LAJIR / DF		0,712		
X1) CDG / AT	0,700		X4) NCG / RL			0,895	
X5) T / AT	0,641		X3) NCG / AT			0,631	
X7) PF / AC	-0,578		X2) CDG / RL			0,614	
X23) (AC + RLP)/(PC + PNC)	0,579		X30) ATIVO FIXO / PL				0,918
X34) DISPONÍVEL / AT		0,917	X29) (PC + PNC) / PL				0,912
X35) DISPONÍVEL / ANC		0,886					
X33) DISPONÍVEL / PC		0,859					
X22) (AC – ESTOQUES) / PC		0,600					
X21) AC / PC		0,553					

Método de Extração: Análise de Componente Principal

Método de Rotação: Varimax com Normalização de Kaiser

a. Rotação convergida em 11 iterações

Fonte: Dados da pesquisa

Os indicadores mais representativos, encontrados pela FATORIAL 02, foram: Necessidade de Capital de Giro sobre Receita Líquida (X4- NCG / RL); Saldo de Tesouraria (X10- $T = AF - PF$); Margem Líquida (X25- LL / RL); Imobilização do Patrimônio Líquido (X30- ATIVO FIXO / PL), Patrimônio Líquido sobre Ativo (X31- PL / AT), Indicador de Estrutura (X34- DISPONÍVEL / AT). Além dos indicadores com maior poder de explicação, encontrados pela análise fatorial, foram utilizados os escores dos dois fatorais na tentativa de se encontrar a melhor combinação de indicadores para os modelos.

Neste sentido, têm-se, a princípio, sete possibilidades de combinações de indicadores para serem testadas: Resultado do método *Stepwise*, gerado por meio da Análise Discriminante, resultado do método *Forward*: LR⁶ gerado por meio da Regressão Logística, os indicadores mais representativos de cada fator, encontrados por meio da Fatorial 1, os indicadores mais representativos de cada fator encontrados por meio da Fatorial 2, o cálculo dos escores da Análise Fatorial 1, o cálculo dos escores da Análise Fatorial 2 e o processo humano de tentativa e erro que pode ser influenciado pelos resultados auferidos com as seis possibilidades utilizadas anteriormente.

Para cada técnica discutida, a seguir, será apresentado apenas um modelo contendo o seu melhor agrupamento de indicadores, para não se prolongar na demonstração de todos os possíveis modelos. Ao final da avaliação das três técnicas, será apresentada uma exemplificação do desempenho de cada agrupamento de indicadores utilizado por modelo, além da comparação das três técnicas.

⁶ Método “passo a frente” (*forward*): é um método em que, inicialmente, tem-se um modelo reduzido, usando como variável auxiliar a variável de maior coeficiente de correlação, tida como uma variável reposta (variável extra). Então, uma nova variável é acrescentada e se o modelo obtido com essa nova variável apresentar melhor desempenho esta é incorporada ao elenco do novo modelo. Este procedimento é repetido até que não se tenha mais nenhuma variável significativa para acrescentar ao modelo, então o processo é finalizado e se tem o modelo final (CHARNET et al., 2008).

4.2 Análise discriminante - AD

Para gerar o modelo de análise discriminante, optou-se, primeiramente, pelo método *stepwise* que apresentou uma acurácia de 89,0% em seus acertos, contudo possuindo um alto nível de erro tipo I⁷. O método *stepwise*, na etapa seis, selecionou os seguintes indicadores como demonstrado na Tabela 12.

Tabela 12 Resultado da sexta etapa do método *stepwise*

Indicadores na análise			
Indicadores	Tolerância	Sig. de F a ser removida	Lambda de Wilks
X8) TEF = Estrutura	0,773	0,018	0,302
X18) LL / AT	0,949	0,000	0,374
X20) LL / PL	0,938	0,000	0,333
X11) NCG = AO – PO	0,892	0,012	0,304
X9) TL = T / (NCG)	0,827	0,011	0,305
X4) NCG / RL	0,732	0,021	0,301

Fonte: Dados da pesquisa

Entretanto, após testar as combinações de indicadores propostos, o modelo desenvolvido com indicadores selecionados, por meio do processo de tentativa e erro, encontrou uma melhor especificação. Neste sentido, o mesmo será apresentado neste tópico como segue.

Para Análise Discriminante, são considerados indicadores significantes aqueles que apresentam significância menor ou igual a 0,05 (sig. < 0,05). Sendo assim, com base na observação da Tabela 13, pode-se concluir que os sete

⁷ O erro tipo I, para pesquisas em risco de crédito, significa classificar empresas insolventes como solventes e o ato da concessão de empréstimo ocorrer em perdas financeiras, por outro lado, o erro tipo II consiste em classificar empresas solventes como insolventes e não conceder o crédito, deixando, assim, de auferir lucros no processo. Nesse sentido, o erro tipo I para uma empresa que oferece crédito tem impacto mais negativo do que o erro tipo II, considerando que este acarretará em perdas financeiras para a mesma.

indicadores separados, para o presente estudo, são indicadores com poder para discriminar os grupos e que podem ser utilizados na análise. Outro dado apresentado é o Lambda de Wilks, que, estatisticamente, representa que quanto menor for o valor atingido pelo indicador juntamente com seu nível de significância, melhor será o seu poder de discriminar entre os grupos (HAIR et al., 2009). Observa-se que o indicador que melhor apresentou essa função foi Tipo de Estrutura Financeira (X8- TEF = Tipos de Estrutura Financeira) com valor de 0,562.

Tabela 13 Testes de igualdade de médias de grupo

	Lambda de Wilks	Z	df1	df2	Sig.
X1) CDG / AT	0,610	54,991	1	86	0,000
X3) NCG / AT	0,743	29,762	1	86	0,000
X8) TEF = Estrutura	0,562	66,905	1	86	0,000
X9) TL = T / (NCG)	0,772	25,355	1	86	0,000
X20) LL / PL	0,836	16,830	1	86	0,000
X25) LL / RL	0,684	39,780	1	86	0,000
X31) PL / AT	0,704	36,123	1	86	0,000

Fonte: Dados da Pesquisa

Este fato é importante uma vez que o índice em questão é um indicador do Modelo Fleuriet, utilizado por Melo e Coutinho (2007) e, também, foco da presente análise. Além do índice de EB, foram selecionados para o modelo os indicadores Capital de Giro sobre Ativo (X1- CDG / AT), Necessidade de Capital de Giro sobre Ativo (X3- NCG / AT) e o Termômetro de Liquidez (X9- TL = T / (|NCG|)) que representam o Modelo Fleuriet. Dos indicadores do Modelo Tradicional de análise financeira, foram selecionados dois indicadores de rentabilidade: Rentabilidade do Patrimônio Líquido (X20- LL / PL) e Margem Líquida (X25- LL / RL) e um indicador de Estrutura: Patrimônio líquido sobre ativo (X31- PL / AT).

A Tabela 14 demonstra que a Matriz de Correlação não apresenta nenhuma correlação mais acentuada a princípio, um indicativo de que não haverá nenhum caso de multicolinearidade – indicadores independentes que possuem relações lineares exatas ou aproximadamente exatas, os quais podem vir a impossibilitar qualquer estimação para a análise discriminante (HAIR et al., 2009).

Tabela 14 Matriz de correlação entre as indicadores independentes

Indicadores ^a	(X1)	(X3)	(X8)	(X9)	(X20)	(X25)	(X31)
X1) CDG / AT	1						
X3) NCG / AT	0,683	1					
X8) TEF	-0,457	-0,293	1				
X9) TL	0,109	-0,143	-0,277	1			
X20) LL / PL	-0,337	-0,111	0,071	0,028	1		
X25) LL / RL	0,341	0,021	-0,030	0,000	-0,077	1	
X31) PL / AT	0,709	0,522	-0,228	-0,063	-0,357	0,279	1

a. A matriz de covariância tem 98 graus de liberdade

Fonte: Dados da Pesquisa

Outro fato importante é o teste da premissa de igualdade de matrizes de covariância, que, neste caso, apresenta-se de forma insatisfatória, já que a sua significância apresentou um valor menor do que 0,05. Sendo assim, não se pode afirmar que as matrizes de covariância são iguais. Contudo, como o programa gerou as outras partes da análise, apenas este teste não indica que houve inviabilização do estudo, tendo em conta que este resultado pode ter ocorrido devido ao tamanho da amostra ou, ainda pela diferença do tamanho dos grupos (CORRAR et al., 2014).

Outra informação relevante para a análise é a correlação canônica, que determina o quanto (porcentagem) a função consegue explicar a discriminação entre os grupos, se comparado ao conceito do R^2 (HAIR et al., 2009). Para o presente modelo, o valor próprio da Correlação canônica foi 0,814, porém, para

se encontrar o valor correto, é necessário elevar a correlação canônica ao quadrado $(0,814)^2$. Sendo assim, pode-se considerar que a função explica 66% da discriminação entre os grupos, que, segundo Corrar et al. (2014), representa um ‘bom’ percentual.

Neste sentido, é preciso verificar a multicolinearidade para os indicadores do modelo discriminante. Neste sentido, como salienta Field (2013), o teste para a multicolinearidade pode ser realizado por vários critérios, entre eles podem-se utilizar os valores de Tolerância e VIF. Desta forma, “um valor de tolerância menor do que 0,1, provavelmente, indica um problema sério de colinearidade. [...] um valor FIV maior do que 10 é motivo de preocupação” (FIELD, 2013, p. 257). Pode-se observar, na Tabela 15, que tanto os valores de Tolerância como os de VIF apresentam estatísticas favoráveis contra a presença de multicolinearidade.

Tabela 15 Coeficientes para multicolinearidade

Indicadores	Estatísticas de colinearidade	
	Tolerância	VIF
X1) CDG / AT	0,134	7,437
X3) NCG / AT	0,307	3,253
X8) TEF = Estrutura	0,408	2,449
X9) TL = T / (NCG)	0,705	1,419
X20) LL / PL	0,858	1,165
X25) LL / RL	0,713	1,403
X31) PL / AT	0,291	3,439

a. Variável Dependente: Situação 0 e 1

Fonte: Dados da Pesquisa

A análise dos Coeficientes da função de classificação permite conhecer um pouco mais sobre qual a importância de cada indicador dentro da Função Discriminante (CORRAR et al., 2014). Observando os dados da Tabela 16, pode-se concluir que os coeficientes (dos indicadores) que apresentaram valores negativos para a função discriminante contribuirão (quanto maior o valor do

indicador) para que a empresa seja classificada abaixo do ponto de corte⁸ e, conseqüentemente, seja considerada como insolvente. Por outro lado, os coeficientes que obtiveram valores positivos contribuirão (quanto maior o valor do indicador) para que a empresa seja considerada no grupo das solventes.

Sendo assim, os indicadores que apresentaram valores negativos para o coeficiente da função discriminante foram: Capital de Giro sobre Ativo (X1- CDG / AT) e Tipos de Estrutura Financeira (X8- TEF = Tipos de Estrutura Financeira), contribuirão para que a empresa seja classificada como insolvente. Por outro lado, os indicadores que apresentarem valores positivos para o coeficiente da função discriminante foram: Necessidade de Capital de Giro sobre Ativo (X3- NCG / AT); Termômetro de Liquidez (X9- TL = T / (|NCG|)); Rentabilidade do Patrimônio Líquido (X20- LL / PL); Margem Líquida (X25- LL / RL), Patrimônio líquido sobre ativo (X31- PL / AT) colaborarão para que a empresa seja classificada como solvente.

Tabela 16 Coeficientes de função discriminante canônica

Indicadores	Função
X1) CDG / AT	-0,180
X3) NCG / AT	1,207
X8) TEF = Estrutura	-0,449
X9) TL = T / (NCG)	0,046
X20) LL / PL	1,036
X25) LL / RL	1,627
X31) PL / AT	0,693
(Constante)	1,649

Coeficientes não padronizados

Fonte: Dados da Pesquisa

⁸ Como discutido no tópico 2.4.1, o ponto de corte ótimo ou escore crítico pode ser obtido, no presente caso, por meio da média ponderada dos centroides, que são o resumo das diferenças entre cada grupo e representam a sua média individual. Esse cálculo possibilita encontrar um ponto de corte para o resultado da função discriminante que definirá se as novas empresas que foram testadas pertencem ao grupo das empresas solventes ou das empresas insolventes.

Uma análise mais detalhada sobre os sinais apresentados pelos indicadores e qual o resultado esperado pela literatura será realizada, em conjunto, para todos os modelos gerados no tópico 4.6 ‘Análise dos indicadores’, de modo a possibilitar uma melhor compreensão da relevância de cada indicador para a análise do risco de crédito.

De posse dos coeficientes da função discriminante canônica não padronizado, pode-se elaborar a função para a Análise Discriminante, ou seja, o *Credit Scoring* gerado pode ser representado pela Equação 21.

$$\begin{aligned}
 Z = & 1,649 - 0,180 \cdot \left(\frac{CDG}{AT}\right) + 1,207 \cdot \left(\frac{NCG}{AT}\right) \\
 & -0,449 \cdot (Tipo\ de\ Estrutura) + 0,046 \cdot \left(\frac{T}{|NCG|}\right) \\
 & +1,036 \cdot \left(\frac{LL}{PL}\right) + 1,627 \cdot \left(\frac{LL}{VL}\right) + 0,693 \cdot \left(\frac{PL}{AT}\right)
 \end{aligned} \tag{21}$$

Elaborada a função para a Análise Discriminante é possível calcular o ponto de corte a partir dos centroides de cada grupo. Os centroides são as médias obtidas com a distribuição individual dos grupos, como pode ser visualizado no Gráfico 1. A média ponderada entre os centroides de cada uma das distribuições se constituirá no ponto de corte da função discriminante.

FUNÇÃO DISCRIMINANTE CANÔNICA




Gráfico 1 Distribuição por grupos
Fonte: Dados da Pesquisa

O resultado obtido para o ponto de corte ótimo é $-0,4978$, este valor servirá para classificar as empresas por meio do seu escore discriminante. Ou seja, as empresas que se encontrarem abaixo do ponto de corte (ponto de corte = $-0,4978$) foram classificadas como pertencentes ao grupo "1" (insolventes) e as empresas que possuem escore discriminante acima do ponto do corte irão ser classificadas como parte do grupo "0" (solventes).

Outro método utilizado na interpretação dos resultados obtidos pela Função Discriminante é a aplicação do Termômetro de Insolvência de Kanitz, em que depois de calculados os desvios padrão e as médias de cada grupo, pode ser obtido como explicado no tópico 2.4.1.

Neste sentido, como demonstrado no Gráfico 2, a empresa cujo cálculo do escore discriminante se encontra em um intervalo entre $0,1263$ até $-0,6049$ será considerada na área de penumbra e será classificada em uma situação indefinida. Sendo assim, esta empresa inspira certos cuidados na concessão de crédito. Estatisticamente, pode-se dizer que o modelo matemático não tem base para afirmar nenhuma classificação nesse intervalo de penumbra (KANITZ, 1974).

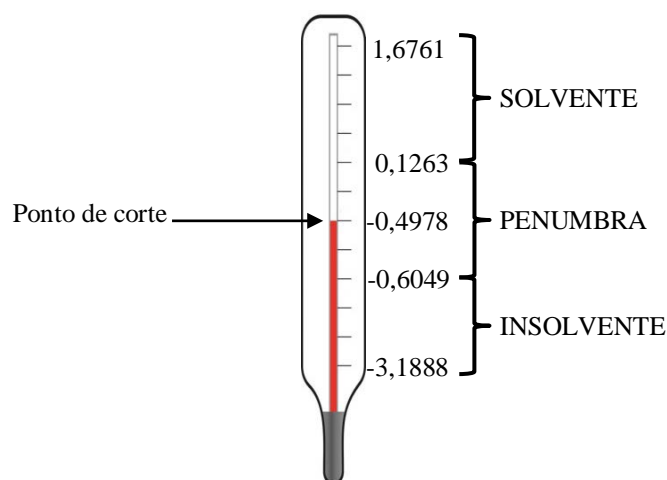


Gráfico 2 Termômetro da insolvência
Fonte: Elaborado pelo autor

Resumidamente, a área de penumbra se encontra entre 0,1263 até -0,6049. Qualquer empresa que estiver abaixo desta região estará em uma situação considerada de insolvência e qualquer empresa que estiver acima será considerada em uma situação de solvência e quanto maior for o seu escore discriminante acima do ponto 0,1263, maiores chances de que esta empresa não apresente problemas financeiros, o oposto, também, pode ser anotado para as empresas insolventes.

Os resultados encontrados pela classificação para a análise discriminante podem ser vistos na Tabela 17. Os casos originais agrupados corretamente representam um percentual de acerto de 90,9%, enquanto os casos selecionados para a validação cruzada (teste de Lachenbruch), confirmam o resultado com o mesmo nível de precisão. Por fim, testando a função para os casos não selecionados, para gerar a função, obtiveram -se 90,9% de acurácia. A função discriminante conseguiu o mesmo nível de acurácia tanto para os casos que foram utilizados para sua criação como para casos externos que não participaram da sua construção.

Tabela 17 Resultados da classificação^{a,b,d}

Classg	Situação	Associação ao grupo prevista		Total		
		Solventes	Insolventes			
Casos selecionados	Original	Contagem	Solventes	51	1	52
			Insolventes	7	29	36
		%	Solventes	98,1%	1,9%	100%
			Insolventes	19,4%	80,6%	100%
	Com validação cruzada ^c	Contagem	Solventes	51	1	52
			Insolventes	7	29	36
		%	Solventes	98,1%	1,9%	100%
			Insolventes	19,4%	80,6%	100%
Casos não selecionados	Original	Contagem	Solventes	17	1	18
			Insolventes	2	13	15
		%	Solventes	94,4%	5,6%	100%
			Insolventes	13,3%	86,7%	100%

a. 90,9% de casos agrupados originais selecionados classificados corretamente

b. 90,9% de casos agrupados originais não selecionados classificados corretamente

c. A validação cruzada é feita apenas para os casos da análise. Na validação cruzada, cada caso é classificado pelas funções derivadas de todos os casos diferentes desse caso

d. 90,9% de casos agrupados com validação cruzada selecionados classificados corretamente

Fonte: Dados da Pesquisa

O nível de precisão global do modelo é de 90,9%, com 110 das 121 empresas classificadas corretamente. Das 70 empresas solventes, 68 são classificadas corretamente e 2 classificadas incorretamente, o que representa uma taxa de acerto de 97,1%. Do grupo com 51 empresas insolventes, 42 classificações corretas e 9 incorretas, o que corresponde a uma taxa de acerto de 82,4%. A probabilidade de se classificar uma empresa insolvente como solvente e incorrer em erro tipo I é de 17,6%, enquanto a probabilidade de se classificar uma empresa solvente como insolvente, erro tipo II, é de 2,9%.

4.3 Regressão logística - RL

Para o cálculo da Regressão Logística, o método *Forward: LR* apresentou os melhores resultados. Apesar do método de *Stepwise* ter demonstrado resultados significativos, o método de *Forward: LR* possibilitou um modelo com estatísticas mais robustas e com um menor percentual de erro tipo I. O primeiro modelo realizado com o método *Forward: LR* possuía a constante, contudo ela não apresentou valores significativos e, por isso, foi excluída do modelo. Sua exclusão acarretou redução da acurácia do modelo, contudo possibilitou a diminuição dos erros tipo I, neste sentido, optou-se por realizar o modelo sem a constante.

Para a Regressão Logística, os testes considerados pseudos- R^2 , Cox & Snell e Nagelkerke podem ser vistos na Tabela 18. O teste Cox & Snell apresentou resultado de 59%, isto é, o conjunto dos indicadores independentes consegue explicar este percentual nas variações ocorridas dentro do log da razão de chance (CORRAR et al., 2014). Já, no valor apresentado para o Nagelkerke, destaca-se que o modelo é capaz de explicar, aproximadamente, 79% das variações atribuídas à variável dependente (solvente/insolvente).

Tabela 18 Testes de Cox Snell e Nagelkerke

Verossimilhança de log -2	R quadrado Cox & Snell	R quadrado Nagelkerke
59,752	0,590	0,787

Fonte: Dados da Pesquisa

Além dos testes apresentados acima, o R^2 pode ser calculado dividindo o Qui-quadrado do modelo, que para o presente modelo é de 107,99, pelo valor original da função inicial de Log-verossimilhança -2 (-2VL), que é de 167,74 (FIELD, 2013). Assim, o cálculo para os valores é: $R^2 = \frac{107,99}{167,74}$, o que indica que o modelo pode explicar 64,5% dos motivos que levam uma empresa a se tornar insolvência. Por outro lado, 35,5% das razões que levam as empresas à insolvência são desconhecidas.

Field (2013) salienta que o teste de Hosmer e Lemeshow testa a hipótese de que os dados observados são, significativamente, diferentes dos valores previstos pelo modelo. Neste sentido, busca-se rejeitar o teste com valores não significativos (Sig. > 0,05), o que significa que o modelo poderá prever bem os valores. Para o presente caso, foi possível rejeitar a hipótese de que os dados observados são diferentes dos valores previstos, como pode ser visto na Tabela 19.

Tabela 19 Teste de Hosmer e Lemeshow

Qui-quadrado	df	Sig.
2,167	8	0,975

Fonte: Dados da Pesquisa

Na Tabela 20, é apresentada a classificação realizada pelo modelo de regressão logística. O modelo apresentou uma precisão de acerto de 90,9%, um nível global de acerto semelhante ao do modelo de análise discriminante realizado anteriormente, entretanto o modelo de regressão logística incorreu em

um percentual menor de erro Tipo I. Nesse sentido, a regressão logística apresentou 8,6% de erro tipo I, ao classificar uma empresa solvente como insolvente e 9,8% de erro tipo II, classificando empresas insolventes como solventes. Os fatores, para o cálculo da regressão logística, apresentaram-se estatisticamente significantes, o que demonstra que o modelo é capaz de classificar as empresas com certo nível de precisão.

Tabela 20 Classificação^a Regressão Logística

Observado		Previsto		Porcentagem correta
		Solventes	Insolventes	
Situação	Solventes	64	6	91,4%
	Insolventes	5	46	90,2%
Porcentagem global				90,9%

a. O valor de recorte é 0,5

Fonte: Dados da Pesquisa

Field (2013) afirma que, para a avaliação da significância dos coeficientes, deve-se primeiro verificar a multicolinearidade, tendo em vista que o modelo de regressão logística é influenciado por ela, assim como um modelo de regressão. Como se pode ver na discussão da análise discriminante o teste para a multicolinearidade pode ser realizado por vários critérios, entre eles podem-se utilizar os valores de Tolerância e VIF. Neste sentido, “um valor de tolerância menor do que 0,1, provavelmente, indica um problema sério de colinearidade. [...] um valor FIV maior do que 10 é motivo de preocupação” (FIELD, 2013, p. 257). Pode observar, na Tabela 21, que tanto os valores de Tolerância quanto os de VIF para o modelo de regressão logística apresentam estatísticas favoráveis contra a presença de multicolinearidade.

Tabela 21 Coeficientes para multicolinearidade

Indicadores	Estatísticas de colinearidade	
	Tolerância	VIF
X3) NCG / AT	0,742	1,348
X16) PL / ET	0,726	1,378
X25) LL / RL	0,820	1,219
X28) PC / (PC + PNC)	0,948	1,055

Fonte: Dados da Pesquisa

Os resultados encontrados para os indicadores no modelo apresentam aspectos positivos ao tentar estimar a probabilidade a partir de cada coeficiente em particular, como se observa na Tabela 22. A Estatística Wald apresenta um coeficiente Wald maior que zero ($wald > 0$), para cada fator, exercendo efeito discriminatório sobre a probabilidade de a empresa ser insolvente ou solvente, os indicadores, também, são significativos a 0,05 ($Sig. < 0,05$). Os coeficientes dos fatores independentes, que se encontram na coluna $Exp(B)$ (25,34), estão dentro do limite estabelecido pelas colunas Inferior e Superior (3,12 a 205,38 respectivamente), assim como todos os outros fatores utilizados.

Tabela 22 Indicadores na equação

	B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. para EXP(B)	
							Inferior	Superior
X3NCGAT	-10,747	3,480	9,537	1	0,002	0,000	0,000	0,020
X16PLET	-2,800	0,731	14,670	1	0,000	0,061	0,015	0,255
X25LLRL	-7,329	1,887	15,089	1	0,000	0,001	0,000	0,026
X28PCPCPNC	3,232	1,068	9,168	1	0,002	25,343	3,127	205,379

a. Indicadores inseridos na etapa 1: X3NCGAT, X16PLET, X25LLRL, X28PCPCPNC

Fonte: Dados da Pesquisa

O modelo de Regressão Logística capaz de classificar as empresas em insolvente e solvente utiliza-se dos coeficientes da coluna B, apresentados na Tabela 22. A equação da Regressão Logística, ou *Credit Scoring* gerado, pode ser representada conforme Equação 22.

$$P(Y=1) = \frac{1}{1 + e^{-(-10,747 \cdot (\frac{NCG}{AT}) - 2,800 \cdot (\frac{PL}{ET}) - 7,329 \cdot (\frac{LL}{VL}) + 3,232 \cdot (\frac{PC}{PC + PNC}))}} \quad (22)$$

Para a equação da regressão logística, observa-se que $P(Y = 1)$ apresenta saída do tipo dicotômica, assumindo apenas dois valores possíveis '0' ou '1'. Neste sentido, quanto mais próximo de 1 for o resultado mais a empresa será considerada insolvente, do contrário, quanto menor for o resultado, aproximando-se de 0, mais a empresa será tratada como solvente. Como o resultado oscila entre '0' e '1', o ponto de corte para a regressão logística é 0,5. Pode -se, ainda, multiplicar este resultado por 100 e interpretá-lo como probabilidade (em %) de uma empresa ser insolvente.

Na regressão logística os coeficientes gerados representam as estimativas que cada variável (indicador) independente causa na variável dependente (quando os outros indicadores se mantêm inalterados), isto é, o sinal (+ ou -) vai determinar qual a direção (solvente = 0, insolvente = 1) que a variável dependente (solvente/insolvente) seguirá. Quanto maior forem os valores para os coeficientes negativos, maior probabilidade terá a empresa de ser solventes (Grupo 0), por outro lado, quanto maior for o valor para os coeficientes positivos, maior será a chance de a empresa pertencer ao grupo das insolventes (Grupo 1).

O indicador que apresenta coeficiente com sinal positivo para a regressão logística é a Composição do Endividamento ($X28 - PC / (PC + PNC)$), neste sentido, quanto maiores forem os valores apresentados para esse indicador,

maiores serão as chances de que a empresa seja classificada como insolvente pelo modelo de regressão logística. Por outro lado, os indicadores que apresentaram coeficientes negativos para o modelo são: Necessidade de Capital de Giro sobre Ativo (X3- NCG / AT); Patrimônio Líquido sobre Exigível Total (X16- PL / ET); Margem Líquida (X25- LL / RL), isto é, altos valores para estes indicadores contribuirão para que a empresa seja classificada como solvente.

Os indicadores Necessidade de Capital de Giro sobre Ativo (X3- NCG / AT) e Margem Líquida (X25- LL / RL), também, foram representativos para o modelo de análise discriminante. Cabe observar que, nos dois modelos (análise discriminante e regressão logística), os indicadores apresentaram os mesmos resultados no que se refere ao direcionamento apresentado: quanto maiores os valores para Necessidade de Capital de Giro sobre Ativo (X3- NCG / AT) e para Margem Líquida (X25- LL / RL), maiores probabilidades de a empresa ser solvente.

Uma análise mais detalhada sobre os sinais apresentados pelos indicadores e qual o resultado esperado pela literatura será realizada em conjunto para todos os modelos gerados no tópico 4.6 'Análise dos indicadores', de modo a possibilitar uma melhor compressão da relevância de cada indicador para a análise do risco de crédito.

4.4 Redes neurais artificiais - RNA

Para o modelo com redes neurais artificiais, foram testadas todas as seis combinações de variáveis possíveis. Contudo, o melhor modelo foi obtido por meio do processo de tentativa e erro. No Quadro 8, são apresentados os parâmetros referentes às configurações realizadas para a rede neural. Esta análise demonstra as configurações realizadas para criação do modelo. Cabe

ressaltar que esta foi a melhor configuração encontrada após diversas opções terem sido testadas.

Quadro 8 Parâmetros das configurações realizadas

Multilayer Perceptron Network
<pre>MLP Situação01 (MLEVEL=N) WITH X4 X9 X16 X17 X20 X25 X28 X31 /RESCALE COVARIATE=STANDARDIZED /PARTITION TRAINING=7 HOLDOUT=3 /ARCHITECTURE HIDDENLAYERS=1 (NUMUNITS=AUTO) HIDDENFUNCTION=TANH OUTPUTFUNCTION=SOFTMAX /CRITERIA TRAINING=BATCH OPTIMIZATION=SCALEDCONJUGATE LAMBDAINITIAL=0.000005 SIGMAINITIAL=0.00005 INTERVALCENTER=0 INTERVALOFFSET=0.5 MEMSIZE=1000 /PRINT CPS NETWORKINFO SUMMARY CLASSIFICATION SOLUTION IMPORTANCE /PLOT NETWORK ROC PREDICTED /SAVE PREDVAL /STOPPINGRULES ERRORSTEPS= 1 (DATA=AUTO) TRAININGTIMER=ON (MAXTIME=15) MAXEPOCHS=AUTO ERRORCHANGE=1.0E-4 ERRORRATIO=0.0010 /MISSING USERMISSING=EXCLUDE.</pre>

Fonte: Dados da pesquisa

Dos parâmetros apresentados no Quadro 8, podem-se destacar: (i) *Rescale Covariate=Standardized* – ajuste das covariáveis que, neste caso, optou-se pela padronização, evitando, assim, alguma discrepância nos dados. Este método utiliza o indicador x_j de cada empresa, subtrai dele a média e a divide pelo desvio-padrão de sua respectiva amostra, $\frac{(x - \bar{x})}{s}$; (ii) *Partition Variable = Partition* – na divisão da amostra foi especificado, aproximadamente, 70% dos dados para treinamento e 30% para validação, o que permite avaliar o desempenho da rede neural (porcentagem de acertos) ao submetê-la a um novo conjunto de dados após seu treinamento (o critério definido em 30/70%, especificou 75,2%, sendo 91 casos para treinamento e 24,8%, sendo 30 casos

para validação); (iii) *Criteria Training=Batch* – de acordo com IBM CORPORATION (2012), o critério de treinamento de Lote consiste no processo em que os pesos sinápticos só são atualizados, depois que todos os registros dos dados passam pelo treinamento, ou seja, a formação de lote usa informações de todos os registros no conjunto de dados de treinamento para atualizar os pesos sinápticos.

As informações da rede são apresentadas na Tabela 23. As covariáveis (número de oito unidades) representam os indicadores selecionados. Para a arquitetura, foi definida uma camada oculta contendo sete neurônios (unidades). A função de ativação, para camada oculta, foi a função *Tangente hiperbólica* e, para a camada de saída, utilizou-se a função de ativação *Softmax*. As funções de ativação foram definidas por apresentar melhor desempenho entre as funções testadas.

Tabela 23 Informações de rede

		Modelo	
Camada de entrada	Covariáveis	1	X4) NCG / RL
		2	X9) TL = T / (NCG)
		3	X16) PL / ET
		4	X17) RL / AT
		5	X20) LL / PL
		6	X25) LL / RL
		7	X28) PC / (PC + PNC)
		8	X31) PL / AT
Número de unidades ^a		8	
Método de reescalonamento para covariáveis		Padronizado	
Camadas ocultas	Número de camadas ocultas	1	
	Número de Unidades na Camada Oculta 1 ^a	7	
	Função de ativação	Tangente hiperbólica	
Camada de saída	Variáveis dependentes	1	
	Número de unidades	2	
	Função de ativação	Softmax	
	Função de erro	Entropia cruzada	

a. Excluindo a unidade de viés

Fonte: Dados da pesquisa

As informações da rede neural possibilitam uma melhor compreensão da arquitetura geral da rede. Segundo a IBM CORPORATION (2012), o *perceptron* de multicamadas (MLP) é uma função de preditores (indicadores independentes) que minimizam o erro de predição dos indicadores-alvo (indicador dependente categórico).

No Gráfico 3, é apresentada a estrutura pré-definida para a arquitetura *feedforward*, para o modelo gerado, em que: a camada de entrada contém os preditores (indicadores econômico-financeiros); uma camada oculta com as unidades não observáveis, sendo o valor de cada unidade oculta alguma função dos preditores; a camada de saída (variável categórica) com os resultados (solvente / insolvente), em que cada neurônio da saída representa uma função das unidades ocultas.

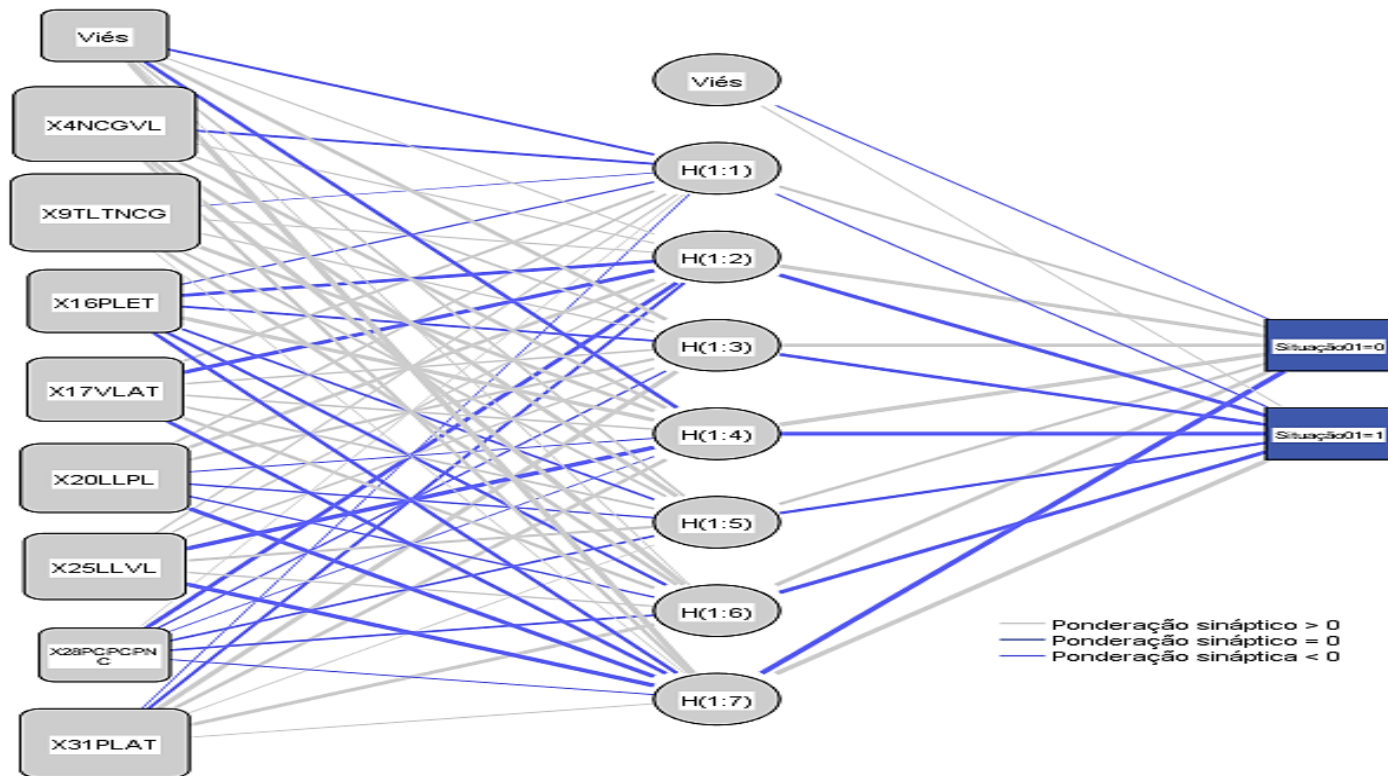


Gráfico 3 Arquitetura *feedforward* com uma camada oculta
 Fonte: Dados da pesquisa

As conexões sinápticas de cor azul, no Gráfico 3, indicam pesos menores do que zero, enquanto as conexões sinápticas de cor cinza representam pesos maiores do que zero. Já o tamanho das caixas em que estão inseridos os indicadores representa a relevância de cada preditor (indicador de entrada) para o modelo gerado.

A relevância de cada indicador para o modelo gerado pode ser melhor visualizado no Gráfico 4, em que são apresentados os indicadores por critério de importância normalizada (percentual). A importância de um indicador independente é calculada com a variação sofrida pela rede em seu valor previsto (saída), para diferentes valores utilizados em cada variável independente. Não se pode afirmar é que a ‘direção’ que os indicadores contribuirão para probabilidade da empresa se solvente ou insolvente, isto é, não se pode afirmar que um maior valor para o indicador X, indica uma maior probabilidade da empresa se tornar insolvente (IBM CORPORATION, 2012).

Para esse aspecto de análise, é preciso utilizar modelos com parâmetros mais facilmente interpretáveis, como é o caso da análise discriminante e da regressão logística conforme demonstrado anteriormente. Segundo Chuang (2013), esse mecanismo de ‘caixa preta’ das redes neurais artificiais proporciona uma falta de transparência na aplicação das redes neurais. Alguns autores do campo como Akkoç (2012), Chuang (2013), Yap, Ong e Husain (2011) e Zhang et al. (2013), dentre outros, fazem menção às dificuldades proporcionadas pela questão da ‘caixa preta’.

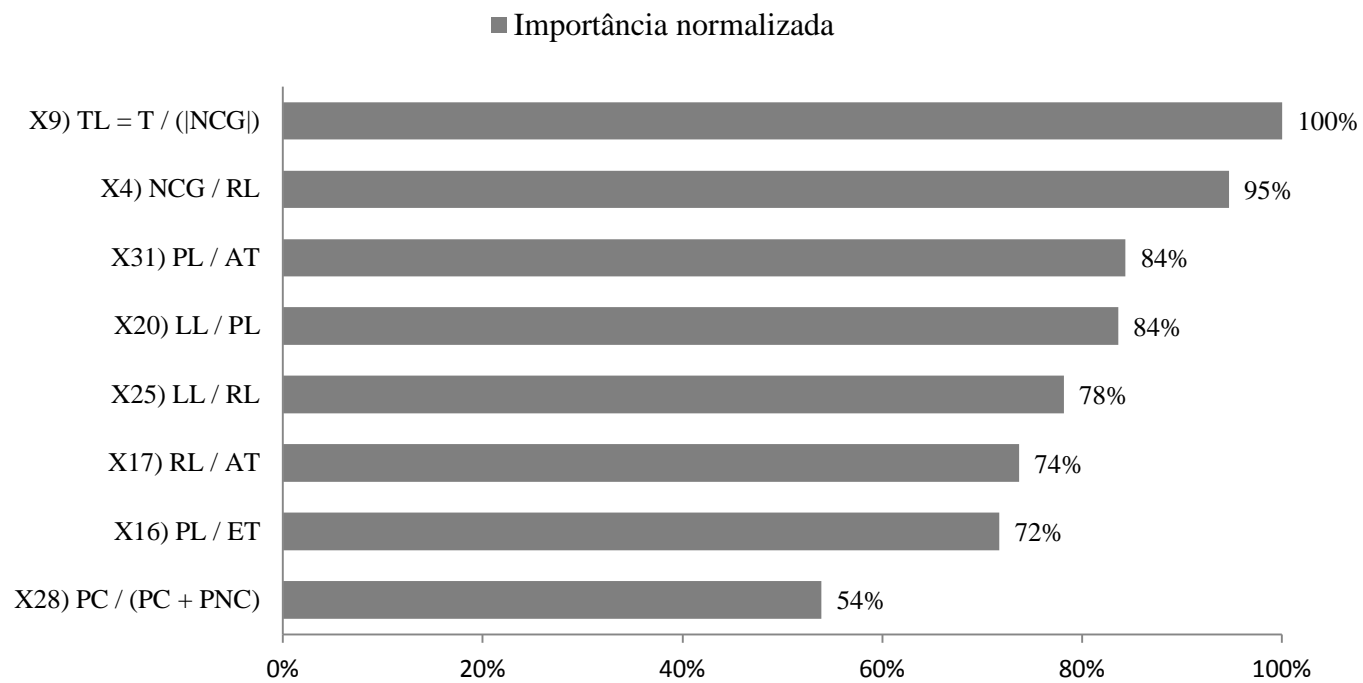


Gráfico 4 Importância dos indicadores independentes
 Fonte: Dados da pesquisa

Os indicadores mais importantes, para o modelo de redes neurais, por ordem de importância, foram: Termômetro de liquidez (X09- $TL = T / (|NCG|)$); Necessidade de Capital de Giro sobre Receita líquida (X03- NCG / RL); Patrimônio líquido sobre ativo (X31- PL / AT); Rentabilidade do Patrimônio Líquido (X20- LL / PL); Margem Líquida (X25 - LL / RL); Giro do ativo (X17- RL / AT); Patrimônio Líquido sobre Exigível Total (X16- PL / ET) e Composição do Endividamento (X28- $PC / (PC + PNC)$).

Um ponto que desperta atenção, no resultado das redes neurais, é que dois indicadores do Modelo Fleuriet, X09 e X03 foram os mais relevantes para construção da melhor rede neural encontrada. Demonstra a importância dos indicadores para a análise de risco de crédito. Como a rede neural não possibilita uma análise mais aprofundada do impacto que cada indicador exerce sobre a probabilidade de solvência ou insolvência, no que se refere ao sinal esperado pela saída, algumas considerações, com base nas médias dos indicadores, para cada grupo (solvente / insolvente), poderão ser realizadas assim como a comparação individual dos indicadores encontrados para os modelos elaborados será realizada no tópico 4.6.

A Tabela 24 apresenta o resumo do modelo. Nela podem ser observadas informações sobre percentual de previsões incorretas da amostra de treinamento (1,1%) e amostra de validação (3,3%). O Erro de entropia cruzada é apresentado, porque a camada de saída utiliza a função de ativação *Softmax* e esta é a função de erro que a rede tenta minimizar durante o treinamento. O treinamento para a rede foi interrompido tendo em vista que critério de erro de treinamento (0,0001) foi obtido, isto é, o erro convergiu.

Tabela 24 Resumo do modelo

Resumo do modelo de Redes Neurais Artificiais		
Treinamento	Erro de entropia cruzada	3,417
	Porcentagem de previsões incorretas	1,1%
	Regra de parada usada	Mudança relativa no critério de erro de treinamento (0,0001) obtida
	Tempo de treinamento	0:00:00,03
Validação	Porcentagem de previsões incorretas	3,3%

Fonte: Dados da pesquisa

Os resultados de classificação para rede neural artificial podem ser visualizados na Tabela 25. A amostra de treinamento obteve 98,9% de acerto, classificando as 49 empresas solventes corretamente e apenas uma empresa insolvente como solvente. A amostra de validação convergiu com 96,7% de acerto, ao classificar 29 empresas corretamente e somente um caso classificado incorretamente, ficando com acerto global de 97,8%.

As classificações, baseadas em casos usados, para criar o modelo (amostra de treinamento), tendem a ser demasiadamente ‘otimistas’, no sentido de que a sua taxa de classificação é inflada (IBM CORPORATION, 2012). Nesse contexto, a amostra de validação contribui para validar o modelo de forma mais apurada.

Tabela 25 Percentual de classificação das redes neurais artificiais

Amostra	Observado	Previsto		% Correto
		Solventes	Insolventes	
Treinamento	Solventes	49	0	100,0%
	Insolventes	1	41	97,6%
	Porcentagem Global	54,9%	45,1%	98,9%
Validação	Solventes	20	1	95,2%
	Insolventes	0	9	100,0%
	Porcentagem Global	66,7%	33,3%	96,7%

Fonte: Dados da pesquisa

As estimativas para os parâmetros são demonstradas na Tabela 26. Nela são apresentados os indicadores (covariáveis) selecionados e seus coeficientes para o cálculo com cada neurônio na camada oculta $H(1: X_j)$, também, é apresentado o ‘Viés’ que se equivale ao ‘Bias’, que funciona como um peso sináptico, como demonstrado no funcionamento do neurônio artificial no tópico 2.4.3. Também são demonstrados os coeficientes para os neurônios da camada oculta $H(1: X_j)$, para o cálculo com cada neurônio na camada de saída $Classg(0: X_j)$ e $Classg(1: X_j)$.

Tabela 26 Estimativas do parâmetro (Matrizes de coeficientes ou pesos de conexão)

Preditor		Previsto								
		Camada oculta 1							Camada de saída	
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	[Classg=0]	[Classg=1]
Camada de entrada	(Viés)	-1,052	0,472	1,749	-1,397	0,803	0,176	3,292		
	X4	-1,047	0,587	0,874	1,606	2,251	3,140	1,104		
	X9	-0,120	0,563	0,720	2,228	0,966	1,726	0,124		
	X16	-0,637	-2,435	-0,969	3,143	-0,907	-1,109	-1,308		
	X17	0,988	-3,092	0,806	0,823	0,941	1,395	-1,705		
	X20	0,854	1,779	1,236	-0,369	-0,764	-0,753	-2,892		
	X25	0,597	0,740	0,777	-4,711	1,176	0,763	-3,491		
	X28	0,018	-1,838	-0,599	-0,161	-0,916	-0,931	-0,357		
	X31	-0,134	-0,978	2,834	1,701	0,138	2,338	0,308		
Camada oculta 1	(Viés)								-0,342	0,292
	H(1:1)								0,982	-0,497
	H(1:2)								2,949	-2,441
	H(1:3)								2,411	-1,806
	H(1:4)								3,727	-3,724
	H(1:5)								1,279	-1,318
	H(1:6)								2,280	-2,846
	H(1:7)								-3,420	3,272

Fonte: Dados da pesquisa

Pela Tabela 26, observa-se que, quando o neurônio ‘Classg=0’ da camada de saída for ativado, a empresa será classificada como solvente e, quando o neurônio ‘Classg=1’ da camada de saída for ativado, a empresa será classificada como insolvente. Os neurônios ‘Classg=0’ e ‘Classg=1’, na camada de saída, representam o indicador categórico dependente (solvente / insolvente), quando se utiliza a função de ativação *Softmax*, na camada de saída, para tentar minimizar a função de erro de entropia cruzada. O valor predito para cada neurônio é a probabilidade de que a empresa pertença à categoria (solvente / insolvente).

4.5 Comparação dos modelos

Para comparação dos modelos, a Tabela 27 apresenta, primeiramente, o nível de acurácia alcançado em cada agrupamento de indicadores para os três modelos testados. Observa-se que o nível geral de acertos para todas as combinações de indicadores foi acima de 80%, de precisão, o que demonstra que as sete opções utilizadas, para agrupar os indicadores, foram bastante relevantes e são passíveis de serem utilizadas para auxiliar o especialista ou estudioso do campo do risco de crédito, no que tange à escolha de quais indicadores utilizar para as análises.

A coluna ‘Tentativa e erro’, na Tabela 27, foi elaborada com intuito de se buscar melhores critérios para os parâmetros de cada modelagem, ou seja, modelos mais parcimoniosos, com maior acurácia nas previsões e com baixos níveis de erro tipo 1. Esse processo de tentativa e erro é o que normalmente ocorre, quando o especialista usa de seu conhecimento e intuição, para alcançar resultados mais precisos, tendo em vista seu conhecimento específico de determinado assunto.

Tabela 27 Comparação dos modelos com indicadores diferentes por modelo

Modelo	<i>Stepwise</i>	<i>Forward: LR</i>	Indicadores da F1	Indicadores da F2	Fatorial 1	Fatorial 2	Tentativa e erro
	% de acerto	% de acerto	% de acerto	% de acerto	% de acerto	% de acerto	% de acerto
Análise discriminante ¹	89,0	86,2	88,0	86,1	89,8	86,0	90,9
Regressão logística	90,1	90,9	86,0	87,6	89,3	86,0	-
Redes neurais artificiais ¹	88,6	89,2	86,4	89,8	92,4	87,9	97,8

¹ Para os valores da Análise Discriminante, foi utilizada a média aritmética simples entre: o resultado dos casos selecionados e o resultado dos casos não selecionados. Para o modelo de Redes Neurais, foi utilizada a média aritmética simples entre: o resultado da amostra de treinamento e o resultado da amostra de validação

Fonte: Elaborada pelo autor

Os agrupamentos de indicadores mais significativos foram a técnica *Forward: LR*, utilizada para regressão logística, com 90,9% de acurácia, também, o processo de tentativa e erro, realizado para a análise discriminante, com 90,9% de precisão e, para as redes neurais, com 97,8% de nível de acerto (TABELA, 27). Cabe observar que todos os agrupamentos realizados contribuíram para se definir os indicadores por meio do processo de tentativa e erro.

A acurácia dos modelos selecionados, quanto ao nível de Precisão Tipo I e Precisão Tipo 2, pode ser observada na Tabela 28. A Precisão Tipo I é o oposto do Erro Tipo I, isto é, quanto maior o nível de Precisão Tipo I, menor o nível de Erro Tipo I, proporcionalmente – o mesmo pode ser considerado para a Precisão Tipo II.

A análise do nível de erro tipo I e tipo II, por meio da precisão dos modelos, é fundamental para uma melhor compreensão da sua qualidade. Na Tabela 28, pode-se ver que a análise discriminante e a regressão logística apresentaram os mesmos níveis de acerto, 90,9%. Contudo, ao se avaliar os níveis de precisão tipo I e tipo II, fica evidente que o modelo de regressão logística apresenta melhor classificação quanto à precisão tipo I, ou seja, o percentual de classificação de empresas insolventes como solventes é maior para o modelo de análise discriminante do que para o modelo de regressão logística, o que acarreta perda do capital investido.

Tabela 28 Acurácias obtidas pelos três modelos finais (aos níveis de erro tipo I e tipo II)

Modelo	Precisão Tipo I	Precisão Tipo II	Precisão Geral
Análise discriminante	82,4%	97,1%	90,9%
Regressão logística	90,2%	91,4%	90,9%
Redes neurais artificiais	98,0%	98,6%	97,8%

Obs: Para os valores da Análise Discriminante, foi utilizada a média aritmética simples entre: o resultado dos casos selecionados e o resultado dos casos não selecionados. Para o modelo de Redes Neurais, foi utilizada a média aritmética simples entre: o resultado da amostra de treinamento e o resultado da amostra de validação

Fonte: Elaborada pelo autor

Os modelos, também, podem ser avaliados por meio da estatística Kolmogorov-Smirnov (KS), que busca verificar o comportamento dos escores das duas amostras de cada modelo. Segundo Selau (2008, p. 96), “espera-se comprovar uma homogeneidade da distribuição dos resultados dos escores nas duas amostras, necessária para utilização do modelo como previsão do risco de crédito a novos clientes”. A Tabela 29 apresenta o resultado do teste KS que é utilizado para testar esta homogeneidade das distribuições dos escores para o modelo de Análise Discriminante.

Tabela 29 Cálculo da estatística KS para os escores do modelo de Análise Discriminante

Faixas de escores	Solventes			Insolventes			KS
	N	%	Acum. %	N	%	Acum. %	
0 a 0,1	56	80,00%	80,00%	3	5,88%	5,88%	74,12%
0,1 a 0,2	7	10,00%	90,00%	3	5,88%	11,76%	78,24%
0,2 a 0,3	1	1,43%	91,43%	2	3,92%	15,69%	75,74%
0,3 a 0,4	2	2,86%	94,29%	0	0,00%	15,69%	78,60%
0,4 a 0,5	2	2,86%	97,14%	1	1,96%	17,65%	79,50%
0,5 a 0,6	0	0,00%	97,14%	0	0,00%	17,65%	79,50%
0,6 a 0,7	0	0,00%	97,14%	1	1,96%	19,61%	77,54%
0,7 a 0,8	1	1,43%	98,57%	4	7,84%	27,45%	71,12%
0,8 a 0,9	0	0,00%	98,57%	1	1,96%	29,41%	69,16%
0,9 a 1	1	1,43%	100%	36	70,59%	100%	0,00%
TOTAL	70	100%		51	100%	Diferença máxima = 0,795	

Fonte: Elaborada pelo autor

A máxima diferença entre as distribuições acumuladas, encontrada para o modelo de Análise Discriminante, foi de 0,795. A Tabela 30 apresenta o resultado do teste KS que é utilizado para testar esta homogeneidade das distribuições dos escores para o modelo de Regressão Logística.

Tabela 30 Cálculo da estatística KS para os escores do modelo de Regressão Logística

Faixas de escores	Solventes			Insolventes			KS
	N	%	Acum. %	N	%	Acum. %	
0 a 0,1	46	65,71%	65,71%	1	1,96%	1,96%	63,75%
0,1 a 0,2	7	10,00%	75,71%	2	3,92%	5,88%	69,83%
0,2 a 0,3	2	2,86%	78,57%	0	0,00%	5,88%	72,69%
0,3 a 0,4	5	7,14%	85,71%	1	1,96%	7,84%	77,87%
0,4 a 0,5	4	5,71%	91,43%	1	1,96%	9,80%	81,62%
0,5 a 0,6	2	2,86%	94,29%	4	7,84%	17,65%	76,64%
0,6 a 0,7	2	2,86%	97,14%	5	9,80%	27,45%	69,69%
0,7 a 0,8	1	1,43%	98,57%	3	5,88%	33,33%	65,24%
0,8 a 0,9	0	0,00%	98,57%	3	5,88%	39,22%	59,36%
0,9 a 1	1	1,43%	100%	31	60,78%	100%	0,00%
TOTAL	70	100%		51	100%		Diferença máxima = 0,816

Fonte: Elaborada pelo autor

A máxima diferença entre as distribuições acumuladas, encontrada para o modelo de Regressão Logística, foi de 0,816. A Tabela 31 apresenta o resultado do teste KS que é utilizado para testar esta homogeneidade das distribuições dos escores para o modelo de Redes Neurais Artificiais.

Tabela 31 Cálculo da estatística KS para os escores do modelo de Redes Neurais Artificiais

Faixas de escores	Solventes			Insolventes			KS
	N	%	Acum. %	N	%	Acum. %	
0 a 0,1	1	1,43%	1,43%	47	92,16%	92,16%	90,73%
0,1 a 0,2	0	0,00%	1,43%	3	5,88%	98,04%	96,61%
0,2 a 0,3	0	0,00%	1,43%	0	0,00%	98,04%	96,61%
0,3 a 0,4	0	0,00%	1,43%	0	0,00%	98,04%	96,61%
0,4 a 0,5	0	0,00%	1,43%	0	0,00%	98,04%	96,61%
0,5 a 0,6	0	0,00%	1,43%	0	0,00%	98,04%	96,61%
0,6 a 0,7	1	1,43%	2,86%	0	0,00%	98,04%	95,18%
0,7 a 0,8	0	0,00%	2,86%	0	0,00%	98,04%	95,18%
0,8 a 0,9	2	2,86%	5,71%	0	0,00%	98,04%	92,32%
0,9 a 1	66	94,29%	100%	1	1,96%	100%	0,00%
TOTAL	70	100%		51	100%	Diferença máxima = 0,966	

Fonte: Elaborada pelo autor

A máxima diferença entre as distribuições acumuladas, encontrada para o modelo de Redes Neurais Artificiais, foi de 0,816. De posse dos valores, para as distribuições dos modelos gerados, pode facilitar a compreensão do teste, ao gerar um gráfico com a visualização do grau de separação entre as empresas solventes e as empresas insolventes por meio dos escores dos modelos (GRÁFICO 5).

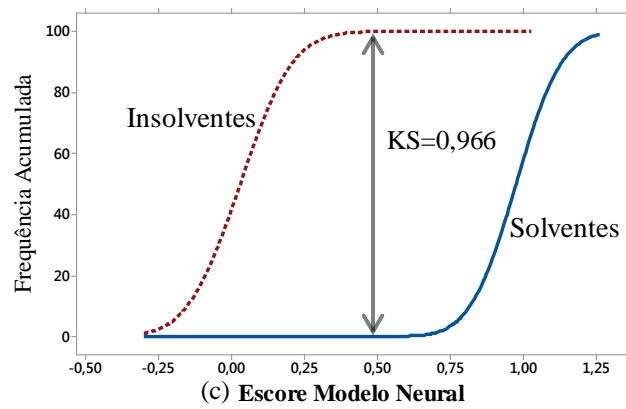

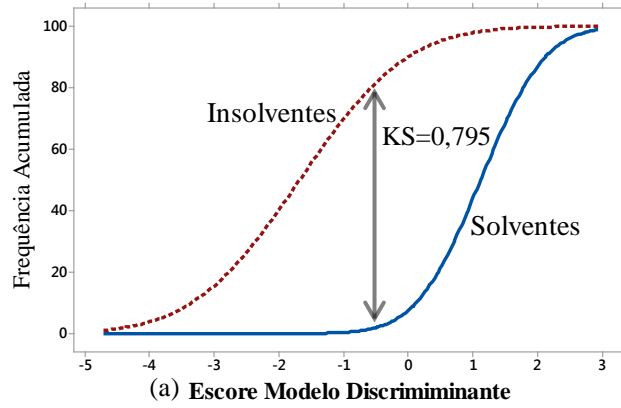


Gráfico 5 Distribuição das frequências acumuladas para KS para os modelos construídos (a = Análise Discriminante; b = Regressão Logística e c = Redes Neurais)
 Fonte: Elaborada pelo autor (Gráficos do *software* Minitab)

O valor da estatística KS, ainda, pode ser comparado a um nível de significância de $\alpha = 0,01$, que pode ser obtido pelo cálculo do ponto crítico:

$$KS_{1\%} = \frac{1,63 \sqrt{\frac{n_1 + n_2}{n_1 * n_2}}}{\sqrt{\frac{70 + 51}{70 * 51}}} = 0,1254.$$

Neste sentido, observa-se que todos os valores máximos encontrados para KS são maiores que o valor D-Crítico de 0,1254. Dado que o valor observado da estatística de teste D-Máximo > D-Crítico, rejeita-se, a hipótese nula de que as distribuições de empresas solventes e empresas insolventes é a mesma. Há, portanto, evidência estatística, ao nível de significância de 0,01, de que os valores da análise se distribuem de forma diferente para o grupo das empresas solventes e insolventes da amostra.

A Tabela 32 apresenta os valores para a estatística KS, segundo Sumihara Filho e Slegers (2010), valores críticos de KS acima de 0,75 são considerados ‘excelentes’ e quanto mais próximo de 1 os valores para o teste, maior será a distancia entre as distribuições acumuladas dos scores dos modelos gerados. Neste contexto, pode-se ver que todos os modelos apresentaram valores superiores a 0,75, contudo, fica evidente a superioridade da Rede Neural, ao apresentar valores de 0,966, em segundo, segue a Regressão Logística com valores de 0,816 e, por último, a Análise Discriminante como valores de 0,795.

Tabela 32 Estatísticas de teste KS para os modelos construídos

		Análise Discriminante	Regressão Logística	Redes Neurais Artificiais
Diferenças Mais Extremas	Absoluto	0,795	0,816	0,966
	Positivo	0,795	0,816	0,966
	Negativo	0,000	0,000	0,000
Z Kolmogorov-Smirnov		4,318	4,434	5,248
Significância Sig. (2 extremidades)		0,000	0,000	0,000

Fonte: Elaborada pelo autor

Além do teste KS, autores como Baesens et al. (2003) e Sicsú (2010) afirmam que, para realizar avaliação do poder discriminador dos modelos de classificação, os analistas costumam utilizar, também, os valores da curva ROC (*Receiver Operating Characteristic Curves*), a qual tem encontrado bons resultados no campo de risco de crédito.

No Gráfico 6, podem-se ver as curvas ROC, obtidas para os três melhores modelos gerados. Observa-se que a análise discriminante obteve a menor área sob a curva. Já a regressão logística apresentou um resultado melhor do que a análise discriminante. Contudo, o melhor desempenho foi apresentado pelas redes neurais, ocupando quase toda a área da curva ROC.




Gráfico 6 Curva ROC para os três modelos apresentados
Fonte: Elaborada pelo autor

Segundo Sumihara Filho e Slegers (2010), como demonstrado na Tabela 2, pode-se classificar os modelos com base nos valores obtidos para a área da curva ROC como: $roc \leq 0,5$ não existe; $0,5 < roc < 0,7$ = baixa; $0,7 \leq roc < 0,8$ = aceitável; $0,8 \leq roc < 0,9$ = excelente e $roc \geq 0,9$ = acima do comum.

Neste sentido, como pode ser visto na Tabela 33, o modelo de análise discriminante foi classificado sob a área da curva ROC como 0,897, ou seja, considerados como excelente. Já os modelos de regressão logística e redes neurais foram classificados com 0,908 e 0,983, respectivamente. Ambos os modelos estão acima do esperado em questão de classificação, apresentando resultados acima de excelente.

Tabela 33 Área sob a curva

Modelos	Área	Erro Padrão ^a	Sig. assintótico ^b	Intervalo de Confiança ^c 95%	
				Limite inferior	Limite superior
Análise Discriminante	0,897	0,034	0,000	0,831	0,964
Regressão Logística	0,908	0,031	0,000	0,847	0,969
Redes Neurais Artificiais	0,983	0,014	0,000	0,956	1,000

A variável ou variáveis de resultado de teste: Análise Discriminante, Regressão Logística, Redes Neurais Artificiais possuem pelo menos um vínculo entre o grupo de estado real positivo e o grupo de estado real negativo. As estatísticas podem ser enviesadas.

a. Sob a suposição não paramétrica

b. Hipótese nula: área real = 0,5

c. Assintótico

Fonte: Elaborada pelo autor

A Tabela 34 apresenta uma síntese com as medidas de desempenho (Nível de Acurácia, Erro Tipo I, Teste KS e Curva ROC) utilizadas para comparar os modelos finas encontrados. Neste resumo, pode-se observar que as

Redes Neurais Artificiais apresentaram melhores resultados em todos os testes realizados, ou seja, alto nível de acurácia, baixo nível de erro Tipo I e altos valores para o teste KS e para a curva ROC.

Tabela 34 Medidas de desempenho para os modelos gerados

Modelos	Nível de Acurácia	Erro Tipo I	Teste KS	Curva ROC
Análise Discriminante	90,9	17,6%	0,795	0,897
Regressão Logística	90,9	9,8%	0,816	0,908
Redes Neurais Artificiais	97,8	2%	0,966	0,983

Fonte: Elaborada pelo autor

No que se refere à classificação, ainda, é possível demonstrar quais foram as empresas classificadas corretamente e quais as empresas cujos modelos gerados não foram capazes de classificar de forma adequada (APÊNDICE C). Neste ponto, é interessante salientar que apenas a empresa Tecnosolo, classificada originalmente como insolvente, foi classificada pelos três modelos como solvente, ou seja, para essa empresa as regras criadas não foram capazes de encontrar os sintomas da insolvência. Esse fato em questão merece um olhar mais atento para as demonstrações contábeis da empresa em busca das minúcias que foram ignoradas pelas modelagens, o que não é o objetivo do presente trabalho.

4.6 Análise dos Indicadores

A Tabela 35 apresenta os indicadores que foram mais representativos para todos os agrupamentos encontrados (todos os agrupamentos de indicadores utilizados alcançaram precisão de acerto acima de 86%). Observa-se, ainda, que

os indicadores do Modelo Fleuriet estão presentes em todos os agrupamentos. Os três modelos finais que apresentaram melhores resultados foram *Forward*: LR para regressão logística, Tentativa e erro, para análise discriminante e Tentativa e erro, para as redes neurais artificiais (com os indicadores '**X**' destacados em negrito na Tabela 35, também se destacou os indicadores que apareceram três ou mais vezes).

Tabela 35 Indicadores selecionados

Indicadores	Forward: LR	Stepwise	Tentativa e erro, AD	Tentativa e erro, RNA	FATORIAL 01	FATORIAL 02	Total de repetições
X1) CDG / AT			X				1
X3) NCG / AT	X		X				2
X4) NCG / RL		X		X	X	X	4
X8) TEF = Estrutura		X	X				2
X9) TL = T / (NCG)		X	X	X			3
X10) T = AF – PF					X	X	2
X11) NCG = AO – PO		X					1
X16) PL / ET	X			X			2
X17) RL / AT				X	X		2
X18) LL / AT		X			X		2
X20) LL / PL		X	X	X			3
X25) LL / RL	X		X	X		X	4
X28) PC / (PC + PNC)	X			X	X		3
X29) (PC + PNC) / PL					X		1
X30) ATIVO FIXO / PL						X	1
X31) PL / AT			X	X		X	3
X34) DISPONÍVEL / AT					X	X	2

Fonte: Elaborada pelo autor

Neste sentido, pode-se dizer que os indicadores selecionados, para os três modelos finais, que apresentaram baixos valores para as empresas insolventes e altos valores para as empresas solventes foram: Necessidade de Capital de Giro sobre Ativo (X3); Termômetro de Liquidez (X9); Rentabilidade do Patrimônio Líquido (X20); Margem Líquida (X25) e Patrimônio líquido sobre ativo (X31). Por outro lado, apenas dois indicadores apresentaram valores maiores para as empresas insolventes: Capital de Giro sobre Ativo (X1) e Tipo de Estrutura Financeira (X8).

No total, dos 35 indicadores selecionados inicialmente, apenas 17 participaram dos agrupamentos para análise. A seguir, são apresentados aqueles que se destacaram nas análises e fizeram parte, no mínimo, de um dos três modelos finais. Neste sentido, dos indicadores apresentados na Tabela 35, não foram explorados os indicadores X18, X29, X30 e X34.

4.6.1 Capital de Giro sobre Ativo (X1- CDG / AT)

O indicador de Capital de Giro sobre Ativo foi representativo apenas para o modelo final gerado com a análise discriminante. A amostra apresentou valores positivos para as empresas solventes (0,166) e valores negativos para as empresas insolventes (-0,302), e média total de -0,031. Contudo, a análise discriminante apresentou um sinal negativo (-) para o coeficiente, o que indica que, dentro da função discriminante, quanto maior for o valor apresentado pelo indicador capital de giro maior será a probabilidade da empresa ser insolvente.

Este foi o único sinal divergente apresentado pelos modelos, como será visto no decorrer desse tópico, já se adianta que, como afirma Olinquevitch e Santi Filho (2009, p. 85), “em termos analíticos, a simples disponibilidade de

CDG não é suficiente para indicar boa saúde econômico-financeira: os recursos próprios disponíveis devem ser adequados às necessidades”.

4.6.2 Necessidade de Capital de Giro (X3- NCG/AT), (X4- NCG/RL) e (X11- NCG)

Olinquevitch e Santi Filho (2009, p. 13) salientam que o valor da Necessidade de Capital de Giro (NCG) pode ser positivo ou negativo. O sinal positivo da NCG indica que as aplicações de Capital de Giro (CDG) são maiores do que as fontes de CDG “expressando que a empresa está investindo recursos no giro do negócio”. Contudo, quando o sinal da NCG se apresenta negativo, indica que as fontes de CDG são maiores do que as aplicações em CDG, “expressando que a empresa está obtendo (financiando-se) com recursos oriundos do giro dos negócios” (OLINQUEVITCH; SANTI FILHO, 2009, p. 13).

Analisando a NCG sobre Receita Líquida e sobre Ativo em conjunto, nota-se que esse foi o único indicador que esteve presente em todos os agrupamentos propostos (TABELA 35). Para o presente estudo, como pode ser observado no Quadro 9, a média da amostra de empresas solventes mostrou-se positiva, enquanto a média para empresas insolventes obteve valores negativos. O que é confirmado pelo modelo de análise discriminante e pelo modelo de regressão logística ao apresentar valores que indicam que quanto maior o valor para NCG, maior a probabilidade de que a empresa venha a ser solvente. Observa-se que o indicador, ainda, foi significativo a 95% para explicar a variação sofrida pela rede neural em seu valor previsto (saída).

Quadro 9 Resumo dos resultados para o indicador X3- NCG/AT, X4- NCG/RL e X11- NCG

Comparativo	Estatística Descritiva (Média)				
	Situação	N	X3	X4	X11
Literatura: Positivo ou Negativo, Padoveze e Benedicto (2010)					
AD = (X3) Sinal* (+) do indicador, quanto maior mais solvente	Insolvente	51	-0,077	-0,114	23.671
RL = (X3) Sinal* (-) do indicador, quanto maior mais solvente	Solvente	70	0,175	0,258	251.798
RNA = (X4) significativo – Importância normalizada de 95%	Total	121	0,069	0,101	155.645

* Os sinais apresentados pela análise discriminante e pela regressão logística são contrários, em razão da forma realizada de cálculo, contudo, os sinais, quando invertidos, representam a mesma tendência para os indicadores, que no presente caso (AD = '+' e RL = '-') é: quanto maior mais solvente

Fonte: Elaborada pelo autor

Empiricamente, estes resultados são divergentes dos apresentados por Minussi, Damacena e Ness Junior (2002, p. 122) que, ao pesquisarem empresas do setor industrial, encontraram valores para o indicador NCG sobre Receita Líquida (“IOG/Venda Líquida - Variável X2”), com médias de 0,80 para o grupo das empresas solventes e média de 3,50 para as empresas insolventes.

Como pode ser visto na Tabela 36, o resultado divergente encontrado em relação ao trabalho de Minussi, Damacena e Ness Junior (2002), deve-se ao fato de que apenas 4 das empresas solventes da amostra encontram-se com a Estrutura Financeira do Tipo 1 ‘Excelente’, ou seja, apresentam CDG e T positivo e NCG negativa, enquanto a maioria das empresas solventes apresentaram Estrutura Financeira do Tipo 2 ‘Sólida’ (32 empresas, CDG, NCG e T positivo), ou Tipo 3 ‘Insatisfatória’ (22 empresas, CDG e NCG positivo e T negativo) em que o valor para a NCG é positivo. Impacta diretamente na média da NCG para empresas solventes serem positivas (0,175 ou 0,258).

Em contrapartida, o que justifica a média das empresas insolventes apresentarem valores negativos para a NCG (-0,077 ou -0,114) é o fato de que

27 empresas insolventes, mais da metade da amostra, estão classificadas nas Estrutura Financeira do Tipo V ‘Muito ruim’ (24 empresas, CDG, NCG e T negativo) e do Tipo VI ‘Alto risco’ (3 empresas, CDG e NCG negativo e T positivo) e, nestes dois tipos de estruturas, as empresas possuem NCG negativa (TABELA 36).

Tabela 36 Agrupamento de empresas por tipos de estrutura e situação financeira

Tipo	CDG	NCG	T	Situação	Empresas Solventes	Empresas Insolventes	Amostra Total
I	+	-	+	Excelente	4	1	5
II	+	+	+	Sólida	32	3	35
III	+	+	-	Insatisfatória	22	6	28
IV	-	+	-	Péssima	11	14	25
V	-	-	-	Muito ruim	1	24	25
VI	-	-	+	Alto risco	0	3	3
Total					70	51	121

Fonte: Adaptado de Braga (1991, p. 10); Marques e Braga (1995, p. 56); Fleuri et al. (2003, p. 15)

Neste sentido, os resultados apresentados estão em conformidade com Padoveze e Benedicto (2010, p. 264) que destacam que “em linhas gerais, as empresas buscam desempenhar um modelo de crescimento constante, ganhando ou ampliando mercados. Dentro dessa premissa, há sempre necessidade adicional de capital de giro, ao longo do tempo”, pois ele representa o recurso necessário para o desempenho das operações da empresa.

Olinquevitch e Santi Filho (2009, p. 13), ainda, afirmam que:

A variável Necessidade Líquida de Capital de Giro (NLCDG) constitui a principal determinante da situação financeira das empresas. Seu valor revela o nível de recursos necessários para manter o giro dos negócios. Diferentemente

dos investimentos no Ativo Permanente, que envolvem decisões de longo prazo e com recuperação lenta de capitais, as contas que compõem as Necessidades Líquidas de Capital de Giro (NLCDG) expressam operações de curto prazo e de efeitos rápidos. Modificações na política de estocagem, na política de crédito e na política de compras produzem efeitos imediatos sobre o fluxo de caixa.

Ainda, segundo Olinquevitch e Santi Filho (2009), a avaliação, assim como o acompanhamento da Necessidade de Capital de Giro, pode ser considerada como um verdadeiro direcionador da situação financeira das empresas.

Na Tabela 36, é importante observar que nenhuma das empresas solventes foi classificada no extrato Tipo VI ‘Alto risco’, entretanto a empresa OGX Petróleo, definida como insolvente, na amostra classificando-a no extrato Tipo I ‘Excelente’, apesar de todos os três melhores modelos terem classificado a empresa como insolvente, como pode ser consultado no APÊNDICE C, na avaliação apenas pelo tipo de estrutura, a situação financeira da OGX Petróleo teria passado despercebida.

4.6.3 Tipo de Estrutura Financeira (X8- TEF = Estrutura do balanço)

Como demonstrado no tópico anterior sobre Necessidade de Capital de Giro, na Tabela 36, os Tipos de Estrutura Financeira foram propostas por Fleuriet et al. (1978) e depois ampliados por Braga (1991), com mais dois níveis. O indicador utilizado no presente estudo representa uma *proxy* com valor 1 para o tipo I, seguindo até um valor 6 para o tipo VI, das estruturas financeiras, ou seja, empresas classificadas como 1 estão no estrato considerado ‘Excelente’, enquanto empresas classificadas como 6, encontram-se no estrato ‘Alto risco’.

O indicador Tipo de Estrutura Financeira foi representativo para o método *stepwise* e, também, para o processo de tentativa e erro que gerou os índices para a análise discriminante, a qual apresentou coeficiente para o indicador em conformidade com o exposto pela literatura. Os valores obtidos pela amostra em estudo, também, apresentam o mesmo comportamento (QUADRO 10).

Quadro 10 Resumo dos resultados para o indicador X8 – Tipo de Estrutura Financeira

Comparativo	Estatística Descritiva		
	Situação	N	Média
Literatura: Quanto menor melhor, Marques e Braga (1995)			
AD = Sinal (-) do indicador, quanto maior mais insolvente	Insolvente	51	4,294
RL = Não significativo	Solvente	70	2,614
RNA = Não significativo	Total	121	3,322

Fonte: Elaborada pelo autor

Cabe salientar que, no modelo de análise discriminante, o teste do Lambda de Wilks para o indicador foi o mais significativo, apresentando o menor valor atingido (0,562), o que representa o alto poder do indicador para discriminar os grupos. Apesar da relevância do indicador para a análise discriminante, ele não apresentou significância para os outros modelos finais. Acredita-se que pelo indicador ter sido mensurado como uma *proxy* de 1 a 6, isso possa ter influenciado para que o mesmo fosse excluído quando utilizado juntamente com os outros indicadores financeiros.

4.6.4 Termômetro de liquidez e o Saldo de Tesouraria (X09- TL e X10- T)

Para Minussi, Damacena e Ness Junior (2002) e Vieira (2008), quanto mais negativo for o valor apresentado pelo saldo de tesouraria, maior será a utilização de recursos de curto prazo oriundos de instituições financeiras, sendo assim, pior tenderá a ser a situação financeira da empresa. Horta (2010) afirma que o Termômetro de liquidez confirma uma reserva financeira para fazer frente às ocasionais expansões da NCG, especialmente, para aquelas de natureza sazonal. Neste sentido, as necessidades temporárias de investimento em giro, quando não cobertas pelos financiamentos de longo prazo, podem ser sustentadas pelo limite do saldo existente (PADOVEZE; BENEDICTO, 2010).

Para a amostra estudada, tanto o saldo de tesouraria quanto o termômetro de liquidez apresentaram valores negativos para as empresas insolventes e valores positivos para as empresas solventes (QUADRO 11). Contudo, apenas o termômetro de liquidez compôs dois dos modelos finais apresentados. O valor positivo para empresas solventes foi confirmado pelo termômetro de liquidez, no modelo de análise discriminante, ao apresentar sinal positivo, indicando que quanto maior for o seu valor mais probabilidade a empresa terá de ser solvente.

Para explicar a variação sofrida pela rede neural em seu valor previsto (saída), o termômetro de liquidez apresentou significância normalizada de 100%. Representou o indicador com maior importância para o melhor modelo encontrado. Este fato corrobora com o postulado por Padoveze e Benedicto (2010, p. 262), ao afirmarem que é por meio das contas de caráter financeiro denominadas contas de tesouraria que se “deveria calcular a liquidez empresarial e a capacidade de solvência da empresa no curto prazo”.

Quadro 11 Resumo dos resultados para o indicador X9 – TL e X10) T

Comparativo	Estatística Descritiva			
	Situação	N	X9 Média	X10 Média
Literatura: Quando positivo melhor, Fleuriot et al. (2003)				
AD = (X9) Sinal (+) do indicador, quanto maior mais solvente	Insolvente	51	-5,871	-246.350
RL = Não significativo	Solvente	70	0,254	20.658
RNA = (X9) significativo – Importância normalizada de 100%	Total	121	-2,328	-91.883

Fonte: Elaborada pelo autor

Empiricamente, os resultados encontrados para o termômetro de liquidez está em conformidade com os apresentados por Horta (2010), ao utilizar o termômetro de liquidez para avaliar diversos setores: setor de materiais básicos (solvente = 0,011 e insolventes = -0,003); setor de bens de consumo cíclico (solvente = 0,010 e insolventes = -0,032); setor de bens de consumo não-cíclico (solvente = 0,002 e insolventes = -0,047); setor econômico de bens industriais (solvente = -0,133 e insolventes = -0,133); setor econômico de construção e transportes (solvente = 0,004 e insolventes = -0,219); setor econômico de tecnologia da informação e telecomunicações (solvente = -0,007 e insolventes = -0,385). O autor, também, utilizou o Saldo de Tesouraria sobre Ativo, contudo, o mesmo não se mostrou significativo para seus modelos.

Empiricamente, os resultados encontrados nas médias da amostra para o saldo de tesouraria estão em conformidade com o trabalho de Minussi, Damacena e Ness Junior (2002), em que os autores, ao utilizarem o Saldo de Tesouraria sobre Receita Líquida, encontraram médias para o grupo das empresas solventes de -0,01 e para o grupo de empresas insolventes -2,90. Segundo os autores, “os dados amostrais refletem claramente a maior dificuldade das empresas insolventes de financiarem-se operacionalmente,

utilizando-se, então, mais intensamente de fontes erráticas” (MINUSSI; DAMACENA; NESS JUNIOR, 2002, p. 121).

4.6.5 Patrimônio Líquido sobre Exigível Total (X16- PL / ET)

O indicador Patrimônio líquido sobre Exigível Total foi proposto por Altman, Baydia e Dias (1979), na tentativa de adaptar os indicadores do modelo original de Altman (1968) para o contexto brasileiro. Altman, Baydia e Dias (1979, p. 22), ao atentarem-se para as características da sua amostra, em que “muitas firmas não têm ações negociadas na Bolsa, não se pode medir o valor de mercado da *equity* (número de ações emitidas vezes última cotação em bolsa)”. Para contornar essa dificuldade, os autores utilizaram o valor contábil do patrimônio líquido sobre exigível total o que resultou em um novo indicador.

O indicador Patrimônio Líquido sobre Exigível Total pode ser considerado como um indicador de Endividamento/Estrutura, isto é, de Alavancagem financeira. Soares e Rebouças (2015, p. 56) afirmam que o indicador “relaciona o Patrimônio Líquido com o Capital de Terceiros e que pode ser entendido como uma medida inversa do risco gerado pela alavancagem ao qual está sujeita uma empresa”.

Conforme Quadro 12, a amostra pesquisada apresenta valores menores para as empresas insolventes, enquanto para as empresas solventes esses valores são maiores. Essa tendência, também, é confirmada pelo sinal gerado pela regressão logística, em que empresas com altos valores para o indicador, possivelmente, foram classificadas como solventes. O Patrimônio Líquido sobre Exigível Total, ainda, foi representativo para explicar a variação no valor previsto (saída) da rede neural em 72% da significância normalizada.

Quadro 12 Resumo dos resultados para o indicador X16 – Patrimônio Líquido/Exigível Total

Comparativo	Estatística Descritiva		
	Situação	N	Média
Literatura: Quanto maior, menor é o grau de alavancagem Soares e Rebouças (2015)			
AD = Não significativo	Insolvente	51	0,120
RL = Sinal (-) do indicador, quanto maior mais solvente	Solvente	70	1,247
RNA = Significativo – Importância normalizada de 72%	Total	121	0,772

Fonte: Elaborada pelo autor

Os resultados apresentados, no Quadro 12, estão em conformidade com os trabalhos empíricos de Altman, Baydía e Dias (1979), em que os autores encontraram médias de 0,35 e 1,14 para as empresas insolventes e empresas solventes, respectivamente. E, também, com o trabalho de Soares e Rebouças (2015) que, ao pesquisarem empresas de capital aberto no Brasil, identificaram que as empresas insolventes apresentaram média de -0,185 e as empresas solventes 1,040. Segundo Soares e Rebouças (2015), o indicador foi considerado importante por todas as técnicas desenvolvidas em seu estudo.

Dessa forma, como o indicador mede a proporção de recursos próprios em relação aos recursos de terceiros na estrutura de capital, pode-se dizer que quanto maior o valor apresentado pelo indicador menor será a alavancagem realizada pela empresa, por outro lado, quanto menor for o valor para esse indicador maior será a alavancagem da empresa. Do exposto, o que os estudos empíricos abordados demonstraram é que empresas insolventes tendem a ser mais alavancadas.

4.6.6 Giro do ativo (X17- RL / AT)

O Giro do ativo é um indicador de Rentabilidade que, segundo Marion (2012, p. 158), “significa a eficiência com que a empresa utiliza seus Ativos, com o objetivo de gerar reais vendas. Quanto mais for gerado de vendas, mais eficiente os ativos serão utilizados”. Padoveze e Benedicto (2010) consideram que o maior giro possível é importante, tendo em vista que existindo lucratividade/margem nos produtos ou serviços ofertados pela empresa e, por conseguinte, receita, há a probabilidade de se gerar maiores lucros e, deste modo, rentabilidade. Os autores, ainda, afirmam que “se o elemento fundamental da rentabilidade é a lucratividade, o caminho é o giro do investimento (do ativo)” (PADOVEZE; BENEDICTO, 2010, p. 122).

Como pode ser visto no Quadro 13, o indicador de giro do ativo atingiu significância normalizada de 74%, para explicar a variação sofrida pela rede neural, apresentando média de giro superior para as empresas solventes.

Quadro 13 Resumo dos resultados para o indicador X17 – Giro do ativo

Comparativo	Estatística Descritiva		
	Situação	N	Média
Literatura: Quanto maior melhor (MARION, 2012)			
AD = Não significativo	Insolvente	51	0,675
RL = Não significativo	Solvente	70	0,793
RNA = Significativo – Importância normalizada de 74%	Total	121	0,743

Fonte: Elaborada pelo autor

Um fato importante é que, para o resultado das redes neurais além do indicador X17 – Giro do ativo, também, foram significativos os indicadores X25 – Margem Líquida e o indicador X31 – Patrimônio líquido sobre ativo, os quais, segundo Padoveze e Benedicto (2010, p. 131), compõem o Modelo DuPont adaptado “para a análise da rentabilidade do patrimônio líquido sob a ótica do

acionista”. A fórmula do Modelo DuPont, segundo os autores, pode ser apresentada na Equação 23. Em que, RSPL significa: Retorno sobre o Patrimônio Líquido.

$$RSPL = \frac{(Giro\ do\ Ativo\ x\ Margem)}{(Participação\ do\ Patrimônio\ Líquido\ no\ Ativo\ Total)} \quad (23)$$

Padoveze e Benedicto (2010, p. 131) esclarecem que o Modelo DuPont adaptado “introduz um elemento adicional de atenção. Quanto menor for a participação de capital próprio (PL), tendencialmente, maior será sua rentabilidade, de acordo com a composição da fórmula”. Portanto, o modelo indica utilizar intensamente o capital de terceiros. Segundo os autores, constitui-se em um modelo de alavancagem financeira com foco na teoria tradicional de finanças, em que existe uma estrutura ótima de capital e as empresas podem aumentar seu valor por meio da alavancagem.

Como o indicador Retorno sobre o Patrimônio Líquido (RSPL) não estava presente nos trabalhos anteriores, nos quais foram selecionados os indicadores para a pesquisa e, como a análise do Modelo DuPont adaptado não é o foco do trabalho, fica apenas a consideração de que essas três variáveis apresentam um relacionamento intrínseco como apontam Padoveze e Benedicto (2010) e que, talvez, uma análise posterior mais profunda deste relacionamento possa trazer maiores contribuições para a análise do risco de crédito.

4.6.7 Rentabilidade do Patrimônio Líquido (X20- LL / PL)

Padoveze e Benedicto (2010, p. 115) consideram a análise da rentabilidade como “a parte mais importante da análise financeira”, tendo em

consideração que ela tem por objetivo evidenciar o retorno do capital investido e elucidar os determinantes dessa rentabilidade. Os autores enfatizam que dentro da análise da rentabilidade o principal indicador é a Rentabilidade do Patrimônio Líquido, uma vez que avalia o capital dos proprietários, assim, sob a ótica dos acionistas, utiliza-se como referência o patrimônio líquido do balanço patrimonial para análise da rentabilidade.

O Quadro 14 apresenta os resultados para a Rentabilidade do Patrimônio Líquido. Pode-se notar que a média da amostra está em conformidade pelo exposto pela literatura. Isso vem a ser reforçado pelo resultado da análise discriminante com sinal positivo indicando que quanto maior for o valor apresentado para Rentabilidade do Patrimônio Líquido, maior será a probabilidade da empresa se encontrar no grupo das empresas solventes. Para explicar a variação sofrida pela rede neural em seu valor previsto (saída), o indicador atingiu significância normalizada de 84%.

Quadro 14 Resumo dos resultados para o indicador X20 – Rentabilidade do PL

Comparativo	Estatística Descritiva		
	Situação	N	Média
Literatura: Quanto maior melhor (PADOVEZE; BENEDICTO, 2010)			
AD = Sinal (+) do indicador, quanto maior mais solvente	Insolvente	51	-0,312
RL = Não significativo	Solvente	70	0,052
RNA = Significativo – Importância normalizada de 84%	Total	121	-0,101

Fonte: Elaborada pelo autor

Matarazzo (2010, p. 115) salienta que a função da Rentabilidade do Patrimônio Líquido é apontar qual a taxa de rendimento do capital próprio, “como o Lucro Líquido se acha expurgado da inflação, a taxa de Rentabilidade do Patrimônio Líquido é real”, por isso pode ser comparada com outros rendimentos no mercado.

Empiricamente, os resultados encontrados estão convergentes com os estudos de Kanitz (1978), em que o autor afirma que a Rentabilidade do Patrimônio Líquido é, em média, três vezes maior nas empresas solventes que nas empresas insolventes, apresentando valores de 5,781% para as empresas insolventes e 21,786% para as empresas solventes. Segundo Kanitz (1978, p. 82), “uma das características da empresa falida é uma dramática queda na rentabilidade”. E, também, com o trabalho de Brito (2005), em que a amostra para empresas insolventes obteve média de -0,36 e a amostra para empresas solventes encontrou média de 0,17.

4.6.8 Margem Líquida (X25 - LL / RL)

Marion (2012, p. 158) considera que a Margem Líquida “significa quantos centavos de cada real de venda restaram após a dedução de todas as despesas (inclusive o Imposto de Renda). Evidente que, quanto maior a margem, melhor”. Segundo Matarazzo (2010), a Margem Líquida indica quanto a empresa obtém de lucro sobre as vendas.

Como pode ser observado no Quadro 15, a média da amostra está em conformidade com a literatura, ou seja, quanto maior o valor apresentado pelo indicador melhor é a margem de lucro alcançada pela empresa em relação ao montante de suas vendas líquidas do período. Este é confirmado pelos sinais apresentados tanto pela análise discriminante quanto pela regressão logística, que afirmaram que quanto maior o valor da margem líquida maiores probabilidades a empresa tem de ser solvente. O indicador, ainda, apresentou importância normalizada de 78% para o modelo de redes neurais.

Quadro 15 Resumo dos resultados para o indicador X25 – Margem Líquida

Comparativo	Estatística Descritiva		
	Situação	N	Média
Literatura: Quanto maior melhor (MARION, 2012).			
AD = Sinal (+)* do indicador, quanto maior mais solvente	Insolvente	51	-0,361
RL = Sinal (-)* do indicador, quanto maior mais solvente	Solvente	70	0,040
RNA = Significativo – Importância normalizada de 78%	Total	121	-0,129

* Os sinais apresentados pela análise discriminante e pela regressão logística são contrários, em razão da forma realizada de cálculo, contudo, os sinais, quando invertidos, representam a mesma tendência para os indicadores, que no presente caso (AD = '+' e RL = '-') é: quanto maior mais solvente

Fonte: Elaborada pelo autor

A margem líquida foi o indicador do Modelo de Análise Financeira Tradicional que mais se destacou, presente em quatro dos agrupamentos de indicadores propostos, além de ter integrado os três modelos (AD, RL e RNA) de maior significância para as análises. Os resultados apresentados estão em conformidade com o estudo empírico, desenvolvido por Brito (2005), que encontrou média de -0,11 para empresas insolventes e média de 0,01 para empresas solventes ao pesquisar empresas de capital aberto no Brasil.

4.6.9 Composição do Endividamento (X28- PC / (PC + PNC))

A composição do endividamento é um indicador de Endividamento/Estrutura que, segundo Matarazzo (2010, p. 90), indica “qual o percentual de obrigações de curto prazo em relação às obrigações totais”, como afirma o autor, quanto menor o seu resultado melhor para a empresa.

Segundo Marion (2012), a empresa que opera com mais dívidas em curto prazo está em condição desfavorável, prejudicando sua situação financeira. Matarazzo (2010) complementa que uma coisa é possuir dívidas de curto prazo

que precisam ser pagas com recursos gerados em curto prazo, e outra é possuir dívidas de longo prazo, em que se dispõe de tempo para pagá-las.

O indicador composição do endividamento, apresentado no Quadro 16, mostrou-se significativo na presente pesquisa, sendo a média da amostra de empresas solventes menor do que a média das empresas insolventes. Isso é reforçado pelo sinal do modelo de regressão logística, ao confirmar o que expressa a literatura, ou seja, quanto menor, maiores probabilidades da empresa ser solvente. O indicador, ainda, foi significativo para o modelo de redes neurais.

Quadro 16 Resumo dos resultados para o indicador X28 – Composição do Endividamento

Comparativo	Estatística Descritiva		
	Situação	N	Média
Literatura: Quanto menor melhor (MATARAZZO, 2010).			
AD = Não significativo	Insolvente	51	0,623
RL = Sinal (+) do indicador, quanto menor mais solvente	Solvente	70	0,569
RNA = Significativo – Importância normalizada de 54%	Total	121	0,592

Fonte: Elaborada pelo autor

Empiricamente, estes resultados estão de acordo com os apresentados por Castro Junior (2003, p. 112), que encontrou para empresas insolventes uma “média de 0,5428” e para empresas solventes uma “média de 0,4085”. Castro Junior (2003) afirma, também, que o mais importante é comprovar a hipótese inicial de que quanto maior for o endividamento de curto prazo maior será a probabilidade da empresa ser classificada no grupo das insolventes. Essa hipótese foi confirmada por Castro Junior (2003) em 5 dos 7 modelos finais gerados.

4.6.10 Patrimônio líquido sobre ativo (X31- PL / AT)

Padoveze e Benedicto (2010, p. 115) observam que o Patrimônio líquido sobre ativo é um indicador de medida de financiamento do ativo e sua finalidade é medir a estrutura de financiamento da empresa. Segundo os autores, esse indicador demonstra quanto do ativo foi financiado por capital próprio, evidenciando o reflexo das políticas de alavancagem financeira.

Como pode ser visto no Quadro 17, o indicador Patrimônio líquido sobre ativo apresentou valor negativo para as empresas insolventes e valor positivo para as empresas solventes. Esta relação, também, foi reforçada pelo modelo de análise discriminante com um sinal positivo para o coeficiente, significando que quanto maior o Patrimônio líquido sobre ativo, maior será a probabilidade da empresa pertencer ao grupo das empresas solventes, ou seja, empresas alavancadas têm maior probabilidade de serem insolventes.

Quadro 17 Resumo dos resultados para o indicador X31 – Patrimônio líquido sobre ativo

Comparativo	Estatística Descritiva		
	Situação	N	Média
Literatura: Representa a estrutura de financiamento da empresa			
AD = Sinal (+) do indicador, quanto maior mais solvente	Insolvente	51	-0,259
RL = Não significativo	Solvente	70	0,480
RNA = Significativo – Importância normalizada de 84%	Total	121	0,169

Fonte: Elaborada pelo autor

Como apresentado na análise do indicador X17 – Giro do ativo, nas considerações sobre o Modelo DuPont adaptado, este fato, como aponta Padoveze e Benedicto (2010), constitui-se em um modelo de alavancagem financeira com foco na teoria tradicional de finanças. Como afirma Durand (1952), se a empresa se expande, para além do ponto da estrutura ótima de

capital, mesmo alcançando melhores rendimentos, ela irá incorrer em custos de falência injustificados.

Empiricamente, os resultados apresentados estão em conformidade com os demonstrados por Brito (2005) que, ao estudar empresas de capital aberto, encontrou valores mais baixos para empresas insolventes (média de 0,34) e valores mais altos para empresas solventes (média de 0,56).

5 CONCLUSÃO

O objetivo do estudo foi verificar se o Modelo Tradicional e o Modelo Fleuriet de análise financeira contribuem para discriminação de empresas brasileiras de capital aberto na análise de concessão de crédito. Para alcançar esse objetivo, alguns passos foram realizados. Primeiramente, foram identificados em trabalhos anteriores indicadores econômico-financeiros utilizados em modelos de risco de crédito, o que permitiu selecionar, a princípio, uma gama de 35 indicadores para teste, sendo 13 indicadores pertencentes ao Modelo Fleuriet e 22 pertencentes ao Modelo Tradicional de análise financeira.

A pesquisa empírica, metodologicamente, foi definida como quantitativa quanto à natureza e explicativa quanto ao tipo e desenvolvida por meio de dados oriundos de pesquisa bibliográfica e documental. As demonstrações financeiras foram coletadas por meio do Economática[®] e do site BM&FBOVESPA. A amostra foi composta por 121 empresas, sendo 70 empresas solventes e 51 empresas insolventes de diversos setores.

De posse da amostra e dos indicadores para o estudo, foi realizada a análise descritiva dos dados e, também, uma ANOVA *one-way*, a qual apresentou resultado satisfatório para a maioria dos indicadores propostos, ou seja, os indicadores foram significativos para classificar empresas solventes e insolventes. Contudo, para buscar modelos mais parcimoniosos, foram propostas sete possibilidades para se utilizar os indicadores, seis agrupamentos e um processo de tentativa e erro. Apesar dos seis agrupamentos terem contribuído para um melhor esclarecimento dos indicadores, os três modelos finais (AD, RL e RNA) foram gerados, um pelo processo de *Forward*: LR (RL) e dois pelo processo de tentativa e erro (AD e RNA).

Todos os pressupostos para a modelagem foram atendidos. Ao todo, para os três modelos e os sete agrupamentos de indicadores propostos, foram

gerados 21 modelos (além dos diversos testes realizados por meio de tentativa e erro), os quais apresentaram acurácia acima de 85% em suas classificações, o que demonstra que, em parte, os agrupamentos propostos obtiveram ‘bons’ resultados.

Entretanto, no decorrer dos resultados, apenas o melhor modelo para cada técnica foi apresentado. Ao se comparar as técnicas utilizadas para prever a insolvência empresarial, pode-se perceber a superioridade das redes neurais artificiais sobre a regressão logística e desta sobre a análise discriminante. Estes resultados foram confirmados pelo nível de acertos apresentados pelas técnicas: análise discriminante 90,9%; regressão logística 90,9%; e as redes neurais artificiais 97,8%.

Outro fato que merece destaque é o nível de acurácia obtido pelos três modelos finais no que se refere à Precisão Tipo I (menor nível de erro tipo I), em que a análise discriminante obteve 82,4%, a regressão logística 90,2%, e as redes neurais artificiais alcançaram 98,0%. A estatística de Kolmogorov-Smirnov (KS), também, apresentou valores excelentes ($ks \geq 75$) para Análise Discriminante (0,795), Regressão Logística (0,816) e Redes Neurais Artificiais (0,966). Isso foi atestado, por meio da curva ROC, ao apresentar valores excelentes para a análise discriminante (0,897), e valores acima do comum para a regressão logística (0,908) e para as redes neurais artificiais (0,983).

Sobre os indicadores finais utilizados para compor os agrupamentos propostos, cabe observar que os indicadores pertencentes ao Modelo Fleuriet foram significativos para todos os agrupamentos. A contribuição do Modelo Fleuriet fica mais clara quando avaliada a participação individual de cada indicador para os três modelos finais de concessão de crédito.

Os dois indicadores mais representativos pertencentes ao Modelo Fleuriet foram o Termômetro de Liquidez e a Necessidade de Capital de Giro, os quais contribuíram para o melhor modelo de redes neurais com 100% e 95% de

significância normalizada respectivamente, ao explicar a variação sofrida pela rede em seu valor previsto (saída).

Os resultados encontrados para o Termômetro de Liquidez demonstram a importância das contas de caráter financeiro denominadas contas de tesouraria para se calcular a liquidez empresarial e a capacidade de solvência da empresa no curto prazo.

A NCG foi o único indicador que fez parte de todos os agrupamentos propostos, constituindo-se na principal determinante da situação financeira das empresas. Em linhas gerais, pode-se dizer que as empresas buscam desempenhar um modelo de crescimento constante, expandindo ou ganhando mercados, neste sentido, existe sempre necessidade adicional de capital de giro, ao longo do tempo, pois o seu valor representa o nível de recursos necessários para manter o giro dos negócios e o desempenho das operações da empresa. Entre os indicadores do Modelo Fleuriet, ainda, destacaram-se o Capital de Giro, Tipo de Estrutura Financeira e o Saldo de Tesouraria.

Entre as contas do Modelo Tradicional de análise financeira, pode-se destacar a Margem Líquida, tendo ela participado de quatro dos 7 agrupamentos de indicadores propostos, além de ter integrado os três modelos de maior significância para a análise discriminante, regressão logística e redes neurais. Outro indicador importante foi a Rentabilidade do Patrimônio Líquido, presente em três dos agrupamentos, também, selecionada para os modelos de análise discriminante e redes neurais artificiais. Outro indicador que participou das técnicas de análise discriminante e redes neurais artificiais foi o Patrimônio líquido sobre ativo, demonstrando que empresas altamente alavancadas têm maior probabilidade de serem insolventes, o que está de acordo com o exposto pela teoria tradicional de finanças empresariais.

Uma das limitações da pesquisa constituiu-se no fato de não ter sido possível realizar os modelos por setores específicos, o que poderia contribuir

tanto para a precisão dos modelos quanto para uma melhor compreensão dos fatores que determinam a insolvência das companhias de capital aberto no Brasil. Outra limitação se refere à peculiaridade encontrada, como o caso da empresa Tecnosolo, originalmente classificada como insolvente foi classificada pelos três modelos como solvente, ou seja, as regras criadas não foram capazes de encontrar os sintomas da insolvência. Este fato em questão foge ao escopo da presente pesquisa e pode ser foco de pesquisas futuras, para descobrir, nas demonstrações contábeis da empresa, as minúcias que não foram consideradas pelas modelagens.

Como recomendações para pesquisas futuras indica-se, primeiramente, a realização de modelos específicos para setores econômicos e em empresas de capital aberto de outros países. Segundo, observa-se a possibilidade de se desenvolver modelos híbridos, utilizando técnicas de inteligência artificial juntamente com outras técnicas que possibilitem uma melhor precisão para a modelagem do risco de crédito. Terceiro, verificar a relevância do Modelo Fleuriet para empresas de capital aberto em outros países, comparando os resultados obtidos com os do presente estudo. Por último, verificar a contribuição do Modelo DuPont adaptado, exposto por Padoveze e Benedicto (2010), para a análise do risco de crédito, tendo em consideração que os três indicadores utilizados, para o cálculo do Retorno sobre o Patrimônio Líquido (RSPL), foram significativos para o modelo de redes neurais artificiais.

Acredita-se que, por meio do presente estudo, pode-se elucidar algumas das características que possuem as empresas insolventes para a presente amostra, tais contribuições são fundamentais para as pesquisas de risco de crédito e contribuem para o desenvolvimento da temática ao se comparar técnicas de análise (AD, RL e RNA) além de, também, avançar na utilização e esclarecimento na metodologia de reclassificação do balanço patrimonial por meio do Modelo Fleuriet. A aplicação gerencial pode ser percebida, ao se

verificar a capacidade preditiva dos modelos gerados na análise dos balanços de empresas insolventes, um ano antes do anúncio da concordata preventiva ou pedido de recuperação judicial.

Por fim, diante do exposto, conclui-se que os indicadores do Modelo Fleuriet contribuem de forma efetiva para prever a insolvência empresarial, ao participarem de todas as análises realizadas e contribuírem como os dois indicadores mais significativos para o melhor modelo encontrado e que as redes neurais apresentam maiores percentuais de acerto no processo de classificação.

REFERÊNCIAS

- ABIYEV, R. H. Credit rating using type-2 Fuzzy Neural Networks. **Mathematical Problems in Engineering**, Cairo, v. 2014, p. 1-8, Mar. 2014.
- AKKOÇ, S. An empirical comparison of conventional techniques, neural networks and the three stage hybrid Adaptive Neuro Fuzzy Inference System (ANFIS) model for credit scoring analysis: the case of Turkish credit card data. **European Journal of Operational Research**, Amsterdam, v. 222, n. 1, p. 168-178, 2012.
- ALMEIDA, F. C.; NAKAO, S. H. Redes neurais. In: CORRAR, L. J. et al. (Coord.). **Análise multivariada: para os cursos de administração, ciências contábeis e economia**. São Paulo: Atlas, 2014. p. 432-459.
- ALTMAN, E. I. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. **The Journal of Finance**, New York, v. 23, n. 4, p. 589-609, 1968.
- ALTMAN, E. I.; BAIDYA, T. K. N.; DIAS, L. M. R. Previsão de problemas financeiros em empresas. **Revista de Administração de Empresas**, São Paulo, v. 19, n. 1, p. 17-28, 1979.
- ALTMAN, E. I.; HOTCHKISS, E. **Corporate financial distress and bankruptcy: predict and avoid bankruptcy, analyze and invest in distressed debt**. 3rd ed. New Jersey: J. Wiley, 2006. 354 p.
- ALTMAN, E. I.; MARÇO, G.; VARETTO, F. Corporate distress diagnosis: comparison using linear discriminant analysis and neural networks: the Italian experience. **Journal of Banking and Finance**, Amsterdam, v. 18, p. 505-529, 1994.
- ALTMAN, E. I.; SABATO, G. Modelling credit risk for SMEs: evidence from the US market. **Abacus-a Journal of Accounting Finance and Business Studies**, Sydney, v. 43, n. 3, p. 332-357, 2007.

ANDRADE, M. M. **Introdução à metodologia do trabalho científico**. 9. ed. São Paulo: Atlas, 2009. 160 p.

ARAÚJO, E. A. T.; COSTA, M. L. O.; CAMARGOS, M. A. Mapeamento da produção científica sobre o modelo Fleuret no Brasil. **Gestão Contemporânea**, Porto Alegre, v. 10, n. 14, p. 311-347, jul./dez. 2013.

ARTIACH, T. et al. The determinants of corporate sustainability performance. **Accounting & Finance**, Bingley, v. 50, n. 1, p. 31-51, 2010.

ASSAF NETO, A. **Estrutura e análise de balanços: um enfoque econômico-financeiro**. 10. ed. São Paulo: Atlas, 2012. 336 p.

ASSAF NETO, A. **Finanças corporativas e valor**. 5. ed. São Paulo: Atlas, 2010. 726 p.

ASSAF NETO, A.; SILVA, C. A. T. **Administração do capital de giro**. 4. ed. São Paulo: Atlas, 2012. 269 p.

ATIYA, A. F. Bankruptcy prediction for credit risk using neural networks: a survey and new results. **IEEE Transactions on Neural Networks**, New York, v. 12, n. 4, p. 929-935, 2001.

BAESENS, B. et al. Benchmarking state-of-the-art classification algorithms for credit scoring. **Journal of the Operational Research Society**, Oxford, v. 54, n. 6, p. 627-635, 2003.

BANCO CENTRAL DO BRASIL. **Relatório de inflação**. Brasília, 2015. 122 p.

BEAVER, W. H. Financial ratios as predictors of failure. **Journal of Accounting Research**, Chicago, v. 4, p. 71-111, 1966.

BELLOVARY, J. L.; GIACOMINO, D. E.; AKERS, M. D. A review of bankruptcy prediction studies: 1930 to present. **Journal of Financial Education**, Milwaukee, v. 33, p. 1-42, 2007.

BRAGA, A. P. et al. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2011. 238 p.

BRAGA, R. Análise avançada do capital de giro. **Caderno de estudos FIPECAFI**, São Paulo, v. 3, n. 3, p. 1-34, 1991.

BRASIL. Congresso Nacional. **Lei nº 6.404**, de 15 de dezembro de 1976. Dispõe sobre as sociedades por ações. Brasília, 1976. Disponível em: <<http://www.cvm.gov.br>>. Acesso em: 22 dez. 2015.

BRASIL. Congresso Nacional. **Lei nº 11.101**, de 9 de fevereiro de 2005. Regula a recuperação judicial, a extrajudicial e a falência do empresário e da sociedade empresaria. Brasília, 2005. Disponível em: <http://www.planalto.gov.br/ccivil_03/_Ato2004-2006/2005/Lei/L11101.htm#art200>. Acesso em: 22 dez. 2015.

BRASIL. Congresso Nacional. **Lei nº 11.638**, de 28 de dezembro de 2007. Altera e revoga dispositivos da Lei nº. 6.404, de 15 de dezembro de 1976, e da Lei n. 6.385, de 7 de dezembro de 1976, e estende às sociedades de grande porte disposições relativas à elaboração e divulgação de demonstrações financeiras. Brasília, 2007. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2007-2010/2007/lei/111638.htm>. Acesso em: 22 dez. 2015.

BRASIL. Congresso Nacional. **Lei nº 11.941**, de 27 de maio de 2009. Altera a legislação tributária federal relativa ao parcelamento ordinário de débitos tributários; concede remissão nos casos em que especifica; institui regime. Brasília, 2009. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2007-2010/2009/lei/11941.htm>. Acesso em: 22 dez. 2015.

BRASIL. Presidência da República. **Decreto-Lei nº 7.661**, de 21 de junho de 1945. Lei de Falências. Brasília, 1945. Disponível em:

<http://www.planalto.gov.br/ccivil_03/decreto-lei/del7661.htm>. Acesso em: 22 dez. 2015.

BRASIL, H. V.; BRASIL, H. G. **Gestão financeira das empresas: um modelo dinâmico**. 4. ed. Rio de Janeiro: Qualitymark, 2008. 163 p.

BRITO, G. A. S. **Mensuração de risco de portfólio para carteiras de crédito a empresas**. 2005. 83 p. Dissertação (Mestrado em Ciências Contábeis) - Universidade de São Paulo, São Paulo, 2005.

BRITO, G. A. S.; ASSAF NETO, A. Modelo de classificação de risco de crédito de empresas. **Revista Contabilidade & Finanças**, São Paulo, v. 19, n. 46, p. 18-29, 2008.

BRITO, G. A. S.; ASSAF NETO, A.; CORRAR, L. J. Sistema de classificação de risco de crédito: uma aplicação a companhias abertas no Brasil. **Revista Contabilidade & Finanças**, São Paulo, v. 20, n. 51, p. 28-43, 2009.

CARVALHO, A. T. **Modelo de previsão de insolvência para empresas comerciais**. 2004. 129 p. Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Florianópolis, 2004.

CARVALHO, F. L. et al. Identificação de indicadores contábeis relevantes para previsão e projeção de rentabilidade. **Revista de Educação e Pesquisa em Contabilidade**, Brasília, v. 4, n. 3, p. 94-110, 2010.

CASTRO JUNIOR, F. H. F. **Previsão de insolvência de empresas brasileiras usando análise discriminante, regressão logística e redes neurais**. 2003. 169 p. Dissertação (Mestrado em Administração) - Universidade de São Paulo, São Paulo, 2003.

CHARNET, R. et al. **Análise de modelos de regressão linear com aplicações**. 2. ed. Campinas: UNICAMP, 2008. 368 p.

CHUANG, C. L. Application of hybrid case-based reasoning for enhanced performance in bankruptcy prediction. **Information Sciences**, New York, v. 236, p. 174-185, July 2013.

CHUANG, C. L.; HUANG, S. T. A hybrid neural network approach for credit scoring. **Expert Systems**, New York, v. 28, n. 2, p. 185-196, 2011.

CONOVER, W. J. **Practical nonparametric statistics**. 3rd ed. New York: J. Wiley, 1999. 584 p.

CORRAR, L. J. et al. **Análise multivariada: para os cursos de administração, ciências contábeis e economia**. São Paulo: Atlas, 2014. 541 p.

CRONE, S. F.; FINLAY, S. Instance sampling in credit scoring: an empirical study of sample size and balancing. **International Journal of Forecasting**, Amsterdam, v. 28, n. 1, p. 224-238, 2012.

CROOK, J. N.; EDELMAN, D. B.; THOMAS, L. C. Recent developments in consumer credit risk assessment. **European Journal of Operational Research**, Amsterdam, v. 183, n. 3, p. 1447-1465, 2007.

DANENAS, P.; GARSVA, G.; GUDAS, S. Credit risk evaluation model development using support vector based classifiers. **Procedia Computer Science**, New York, v. 4, n. 4, p. 1699-1707, June 2011.

DIMITRAS, A. I.; ZANAKIS, S. H.; ZOPOUNIDIS, C. A survey of business failures with an emphasis on prediction methods and industrial applications. **European Journal of Operational Research**, Amsterdam, v. 90, n. 3, p. 487-513, 1996.

DURAND, D. Costs of debt and equity funds for business: trends and problems of measurement. In: CONFERENCE ON RESEARCH IN BUSINESS FINANCE, 1952. **Proceedings...** [S.l.]: NBER, 1952. p. 215-262.

DURAND, D. Risk elements in consumer installment lending. **Studies in Consumer Installment Financing**, New York, v. 8, p. 1-101, 1941.

DURNEV, A.; KIM, H. To steal or to not steal: firm attributes, legal environment, and valuation. **Journal of Finance**, New York, v. 60, n. 3, p. 1461-1493, 2005.

EIFERT, D. S. **Análise quantitativa na concessão de crédito versus inadimplência: um estudo empírico**. 2003. 81 p. Dissertação (Mestrado em Administração) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2003.

ELIZABETSKY, R. **Um modelo matemático para decisão no banco comercial**. 1976. 190 p. Dissertação (Mestrado em Engenharia de Produção) - Escola Politécnica, Universidade de São Paulo, São Paulo, 1976.

FIELD, A. **Descobrimo a estatística usando o SPSS**. Porto Alegre: Artmed, 2013. 688 p.

FINLAY, S. Multiple classifier architectures and their application to credit risk assessment. **European Journal of Operational Research**, Amsterdam, v. 210, n. 2, p. 368-378, 2011.

FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of Eugenics**, London, v. 7, n. 2, p. 179-188, 1936.

FLACH, P. A. ROC analysis. In: _____. **Encyclopedia of machine learning**. New York: Springer, 2010. p. 869-875.

FLEURIET, M. et al. **A dinâmica financeira das empresas brasileiras: um método de análise, orçamento e planejamento financeiro**. Belo Horizonte: Fundação Dom Cabral, 1978. 181 p.

FLEURIET, M. et al. **O Modelo Fleuriet**: a dinâmica financeira das empresas brasileiras: um método de análise, orçamento e planejamento financeiro. 3. ed. Rio de Janeiro: Campus, 2003. 169 p.

GARCIA, F.; GIMENEZ, V.; GUIJARRO, F. Credit risk management: a multicriteria approach to assess creditworthiness. **Mathematical and Computer Modelling**, Oxford, v. 57, n. 7/8, p. 2009-2015, Apr. 2013.

GARCIA, F.; GUIJARRO, F.; MOYA, I. Monitoring credit risk in the social economy sector by means of a binary goal programming model. **Service Business**, Heidelberg, v. 7, n. 3, p. 483-495, 2013.

GARSON, D. G. **PA 765 Statnotes**: an online textbook. Disponível em: <<http://www2.chass.ncsu.edu/garson/pa765/statnote.htm>>. Acesso em: 22 dez. 2015.

GIL, A. C. **Como elaborar projetos de pesquisa**. 5. ed. São Paulo: Atlas, 2010. 200 p.

GUIMARÃES, I. A.; CHAVES NETO, A. Reconhecimento de padrões: metodologias estatísticas em crédito ao consumidor. **RAE-Eletrônica**, Rio de Janeiro, v. 1, n. 2, p. 1-14, 2002.

HAIR, J. F. et al. **Análise multivariada de dados**. 6. ed. Porto Alegre: Bookman, 2009. 688 p.

HARRIS, T. Quantitative credit risk assessment using support vector machines: broad versus Narrow default definitions. **Expert Systems With Applications**, New York, v. 40, n. 11, p. 4404-4413, 2013.

HASTINGS JUNIOR, C. et al. Low moments for small samples: a comparative study of order statistics. **The Annals of Mathematical Statistics**, Ann Arbor, v. 18, p. 413-426, 1947.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

HORTA, R. A. M. **Uma metodologia de mineração de dados para a previsão de insolvência de empresas brasileiras de capital aberto**. 2010. 151 p. Tese (Doutorado em Engenharia Civil) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2010.

HOSMER JUNIOR, D. W.; LEMESHOW, S. **Applied logistic regression**. New York: J. Wiley, 2004. 383 p.

HUANG, Z. et al. Credit rating analysis with support vector machines and neural networks: a market comparative study. **Decision Support Systems**, Amsterdam, v. 37, n. 4, p. 543-558, 2004.

IBM CORPORATION. **IBM SPSS Neural Networks 21**. 2012. Disponível em: <ftp://public.dhe.ibm.com/software/analytics/spss/documentation/statistics/21.0/en/client/Manuals/IBM_SPSS_Neural_Network.pdf>. Acesso em: 11 dez. 2015.

ITURRIAGA, F. J. L.; SANZ, I. P. Bankruptcy visualization and prediction using neural networks: a study of US commercial banks. **Expert Systems with Applications**, New York, v. 42, n. 6, p. 2857-2869, 2015.

IUDÍCIBUS, S. **Análise de balanços**. 10. ed. São Paulo: Atlas, 2014. 254 p.

JU, Y. H.; SOHN, S. Y. Updating a credit-scoring model based on new attributes without realization of actual data. **European Journal of Operational Research**, Amsterdam, v. 234, n. 1, p. 119-126, 2014.

KANITZ, S. C. **Como prever falências**. São Paulo: McGraw-Hill do Brasil, 1978. 177 p.

KANITZ, S. C. Como prever falências de empresas. **Revista Negócios em Exame**, São Paulo, p. 95-102, dez. 1974.

KHASHEI, M. et al. A bi-level neural-based fuzzy classification approach for credit scoring problems. **Complexity**, New York, v. 18, n. 6, p. 46-57, July/Aug. 2013.

KIM, S. Y. Prediction of hotel bankruptcy using support vector machine, artificial neural network, logistic regression, and multivariate discriminant analysis. **Service Industries Journal**, London, v. 31, n. 3, p. 441-468, 2011.

KIMURA, H. et al. **Value-at-Risk**: como entender e calcular o risco pelo VaR: uma contribuição para a gestão no Brasil. Ribeirão Preto: Inside Books, 2008. 223 p.

KNIGHT, F. H. **Risk, uncertainty and profit**. 5th ed. Washington: Beard Books, 2002. 173 p.

KOU, G.; WU, W. An analytic hierarchy model for classification algorithms selection in credit risk analysis. **Mathematical Problems in Engineering**, Cairo, v. 2014, p. 1-7, May 2014.

KRISTOF, T.; VIRAG, M. Data reduction and univariate splitting - do they together provide better corporate bankruptcy prediction? **Acta Oeconomica**, Veszprém, v. 62, n. 2, p. 205-228, 2012.

KRUPPA, J. et al. Consumer credit risk: individual probability estimates using machine learning. **Expert Systems with Applications**, New York. v. 40, n. 13, p. 5125-5131, 2013.

LEE, S.; CHOI, W. S. A multi-industry bankruptcy prediction model using back-propagation neural network and multivariate discriminant analysis. **Expert Systems with Applications**, New York, v. 40, n. 8, p. 2941-2946, 2013.

LI, X.; LIU, G. Y.; QI, J. X. Fuzzy neural and chaotic searching hybrid algorithm and its application in electric customers's credit risk evaluation. **Journal of Central South University of Technology**, Changsha, v. 14, n. 1, p. 140-143, 2007.

LOGAN, M. **Biostatistical design and analysis using R: a practical guide**. Chichester: J. Wiley, 2011. 546 p.

LUDWIG JUNIOR, O.; MONTGOMERY, E. **Redes neurais: fundamentos e aplicações com programas em C**. Rio de Janeiro: Ciência Moderna, 2007. 125 p.

MARCONI, M. A.; LAKATOS, E. M. **Fundamentos de metodologia científica**. 6. ed. São Paulo: Atlas, 2005. 315 p.

MARION, J. C. **Análise das demonstrações contábeis: contabilidade empresarial**. 7. ed. São Paulo: Atlas, 2012. 292 p.

MARQUES, J. A. V. C.; BRAGA, R. Análise dinâmica do capital de giro: o Modelo Fleuriet. **Revista de Administração de Empresas**, São Paulo, v. 35, n. 3, p. 49-63, 1995.

MARTINS, G. A.; THEÓPHILO, C. R. **Metodologia da investigação científica para ciências sociais aplicadas**. São Paulo: Atlas, 2009. 264 p.

MARTINS, M. S. **A previsão de insolvência pelo modelo de Cox: uma contribuição para a análise de companhias abertas brasileiras**. 2003. 102 p. Dissertação (Mestrado em Administração) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2003.

MATARAZZO, D. C. **Análise financeira de balanços: abordagem gerencial**. 7. ed. São Paulo: Atlas, 2010. 372 p.

MATEUS, R. S. **Análise de insolvência empresarial: uma abordagem financeira fundamentalista com aplicação do método estatístico multivariado e da técnica discriminante**. 2010. 79 p. Dissertação (Mestrado Profissional em Desenvolvimento Regional e Gestão de Empreendimentos Locais) - Universidade Federal de Sergipe, São Cristóvão, 2010.

MATHWORKS. **Neural Network Toolbox™ user's guide R2012b.**

MathWorks Corporation, 2012. Disponível em:

<http://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf>. Acesso em: 4 dez. 2015.

MATIAS, A. B. **Contribuição às técnicas de análise financeira:** um modelo de concessão de crédito. 1978. 101 p. Monografia (Graduação em Administração) - Universidade de São Paulo, São Paulo, 1978.

MELO, A. C.; COUTINHO, E. S. O modelo Fleuriet como indicador conjunto de solvência e rentabilidade. In: ENCONTRO DA ANPAD, 31., 2007, Rio de Janeiro. **Anais...** Rio de Janeiro, 2007. 1 CD-ROM.

MINUSSI, J. A.; DAMACENA, C.; NESS JUNIOR, W. L. Um modelo de previsão de solvência utilizando regressão logística. **Revista de Administração Contemporânea**, Curitiba, v. 6, n. 3, p. 109-128, 2002.

NAVA, M. A. R. Análisis financiero: una herramienta clave para una gestión financiera eficiente. **Revista Venezolana de Gerencia**, Maracaibo, v. 14, n. 48, p. 606-628, 2009.

NIKOLIC, N. et al. The application of brute force logistic regression to corporate credit scoring models: evidence from Serbian financial statements. **Expert Systems with Applications**, New York, v. 40, n. 15, p. 5932-5944, 2013.

ODOM, M. D.; SHARDA, R. A neural network model for bankruptcy prediction. In: IJCNN INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 1990, San Diego. **Proceedings...** San Diego, 1990. p. 163-168.

OHLSON, J. Financial ratios and the probabilistic prediction of bankruptcy. **Journal of Accounting Research**, Chicago, v. 18, n. 1, p. 109-131, 1980.

OLINQUEVITCH, J. L.; SANTI FILHO, A. **Análise de balanços para controle gerencial: demonstrativos contábeis exclusivos do fluxo de tesouraria**. 5. ed. São Paulo: Atlas, 2009. 248 p.

OLIVEIRA, J. G. C.; ANDRADE, F. W. M. Comparação entre medidas de performance de modelos de credit scoring. **Tecnologia de Crédito**, São Paulo, n. 33, p. 35-47, 2002.

ONUSIC, L. M. et al. Estudo exploratório utilizando as técnicas de análise por envoltória de dados e redes neurais artificiais na previsão de insolvência de empresas. **FACEF Pesquisa**, Franca, v. 9, n. 2, p. 125-136, 2006.

ORESKI, S.; ORESKI, G. Genetic algorithm-based heuristic for feature selection in credit risk assessment. **Expert Systems with Applications**, New York, v. 41, n. 4, p. 2052-2064, 2014.

PADOVEZE, C. L.; BENEDICTO, G. C. **Análise das demonstrações financeiras**. 3. ed. São Paulo: Cengage Learning, 2010. 298 p.

PEDERZOLI, C.; THOMA, G.; TORRICELLI, C. Modelling credit risk for innovative SMEs: the role of innovation measures. **Journal of Financial Services Research**, New York, v. 44, n. 1, p. 111-129, 2013.

PEREIRA, J. M.; DOMÍNGUEZ, M. Á. C.; OCEJO, J. L. S. Modelos de previsão do fracasso empresarial: aspectos a considerar. **Tékhné-Revista de Estudos Politécnicos**, Botucatu, n. 7, p. 111-148, 2007.

PRADO, J. W. et al. Análise multivariada de dados em pesquisas sobre risco de crédito e falência: um estudo bibliométrico em múltiplas áreas do conhecimento (1968-2014). In: ENCONTRO DA ASSOCIAÇÃO NACIONAL DOS PROGRAMAS DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO, 39., 2015, Belo Horizonte. **Anais...** Belo Horizonte: ANPAD, 2015. p. 1-17.

PRADO, J. W. et al. Multivariate analysis of credit risk and bankruptcy research data: a bibliometric study involving different knowledge fields (1968-2014). **Scientometrics**, Amsterdam, v. 106, n. 3, p. 1007-1029, Jan. 2016.

ROSS, S. A.; WESTERFIELD, R. W.; JAFFE, J. **Administração financeira: corporate finance**. 2. ed. São Paulo: Atlas, 2009. 1072 p.

RUSSELL, S. J.; NORVIG, P. **Inteligência artificial**: referência completa para cursos de computação. Rio de Janeiro: Campus, 2004. 1021 p.

SABATO, G. Modelos de Scoring de risco de crédito. **Revista Tecnologia de Crédito**, São Paulo, v. 1, n. 68, p. 29-47, 2009.

SANTOS, J. O. **Análise de crédito**: empresas, pessoas físicas, agronegócio e pecuária. 5. ed. São Paulo: Atlas, 2012. 334 p.

SANVICENTE, A. Z.; MINARDI, A. M. A. F. **Identificação de indicadores contábeis significativos para a previsão de concordata de empresas**. São Paulo: Instituto Brasileiro de Mercado de Capitais, 1998. 12 p. Working Paper.

SANVICENTE, A. Z.; MINARDI, A. M. A. F. **Migração de risco de crédito de empresas brasileiras**: uma aplicação de análise de clusters na área de crédito. São Paulo: Instituto Brasileiro de Mercado de Capitais, 1999. 14 p. Working Paper.

SAUNDERS, A. M. **Medindo o risco de crédito**: novas abordagens para *value at risk* e outros paradigmas. Rio de Janeiro: Qualitymark, 2000. 181 p.

SCARPEL, R. A. Previsão de insolvência de empresas utilizando support vector machine. **Revista de Economia e Administração**, São Paulo, v. 7, n. 3, p. 281-295, 2008.

SCHRICKEL, W. K. **Análise de crédito**: concessão e gerencia de empréstimos. 5. ed. São Paulo: Atlas, 2000. 353 p.

SEBASTIÃO, J. **Análise das demonstrações financeiras como fator determinante na tomada de decisão**: estudo de caso de entidades angolanas.

2014. 64 p. Tese (Doutorado em Contabilidade e Finanças) - Instituto Politécnico de Setúbal, Escola Superior de Ciências Empresariais, Setúbal, Portugal, 2014.

SELAU, L. P. R. **Construção de modelos de previsão de risco de crédito.** 2008. 129 p. Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

SICSÚ, A. L. **Credit scoring:** desenvolvimento, implantação, acompanhamento. São Paulo: Blucher, 2010. 180 p.

SILVA, J. P. **Administração de crédito e previsão de insolvência.** São Paulo: Atlas, 1983. 139 p.

SILVA, J. P. **Análise financeira das empresas.** 11. ed. São Paulo: Atlas, 2012. 585 p.

SILVA, J. P. **Gestão e análise de risco de crédito.** 6. ed. São Paulo: Atlas, 2008. 421 p.

SILVA, J. P. **Modelos para classificação de empresas com vistas a concessão de crédito.** 1982. 112 p. Dissertação (Mestrado em Administração de Empresas) - Fundação Getúlio Vargas, São Paulo, 1982.

SILVEIRA, A.; BARROS, L.; FAMÁ, R. Atributos corporativos, qualidade da governança corporativa e valor das companhias abertas no Brasil. **Revista Brasileira de Finanças**, Rio de Janeiro, v. 4, n. 1, p. 1-30, 2006.

SOARES, R. A.; REBOUÇAS, S. M. D. P. Avaliação do desempenho de técnicas de classificação aplicadas à previsão de insolvência de empresas de capital aberto brasileiras. **Revista ADM. MADE**, Rio de Janeiro, v. 18, n. 3, p. 40-61, 2015.

SOHN, S. Y.; KIM, Y. S. Behavioral credit scoring model for technology-based firms that considers uncertain financial ratios obtained from relationship banking. **Small Business Economics**, Dordrecht, v. 41, n. 4, p. 931-943, 2013.

SUMIHARA FILHO, H.; SLEEGERS, L. C. Valores de referência para os principais indicadores de acurácia dos modelos de escoragem. **Serasa Experian - Tecnologia de Crédito**, São Paulo, n. 73, p. 31-45, ago. 2010.

SWALES, G. S.; YOON, Y. Applying artificial neural networks to investments analysis. **Financial Analysts Journal**, New York, v. 48, n. 5, p. 78-80, 1992.

TAM, K. Y. Neural network models and the prediction of bank bankruptcy. **Omega-International Journal of Management Science**, London, v. 19, n. 5, p. 429-445, 1991.

TINOCO, M. H.; WILSON, N. Financial distress and bankruptcy prediction among listed companies using accounting, market and macroeconomic variables. **International Review of Financial Analysis**, Greenwich, n. 30, p. 394-419, 2013.

TSAI, M. C. et al. The consumer loan default predicting model - an application of DEA-DA and neural network. **Expert Systems with Applications**, New York, n. 36, p. 11682-11690, 2009.

VAROTTO, S. Stress testing credit risk: the great depression scenario. **Journal of Banking & Finance**, Amsterdam, v. 36, n. 12, p. 3133-3149, 2012.

VERGARA, S. C. **Projetos e relatórios de pesquisa em administração**. 9. ed. São Paulo: Atlas, 2008. 94 p.

VIEIRA, M. V. **Administração estratégica do capital de giro**. 2. ed. São Paulo: Atlas, 2008. 326 p.

VIRGILLITO, S. B.; FAMÁ, R. Estatística multivariada na construção de modelos para análise do risco de crédito e previsão de insolvência de empresas. **Revista Integração**, Brasília, v. 53, n. 13, p. 105-118, 2008.

WILSON, R. L.; SHARDA, R. Bankruptcy prediction using neural networks. **Decision Support Systems**, Amsterdam, v. 11, p. 545-557, 1994.

WOSNITZA, J. H.; LEKER, J. Why credit risk markets are predestined for exhibiting log-periodic power law structures. **Physica A: Statistical Mechanics and its Applications**, London, v. 393, p. 427-449, Jan. 2014.

YANG, Z.; YOU, W.; JI, G. Using partial least squares and support vector machines for bankruptcy prediction. **Expert Systems with Applications**, New York, v. 38, n. 7, p. 8336-8342, 2011.

YAP, B. W.; ONG, S. H.; HUSAIN, N. H. M. Using data mining to improve assessment of credit worthiness via credit scoring models. **Expert Systems with Applications**, New York, v. 38, n. 10, p. 13274-13283, 2011.

YEH, C. C.; CHI, D. J.; HSU, M. F. A hybrid approach of DEA, rough set and support vector machines for business failure prediction. **Expert Systems with Applications**, New York, v. 37, n. 2, p. 1535-1541, 2010.

YU, L. Credit risk evaluation with a least squares fuzzy support vector machines classifier. **Discrete Dynamics in Nature and Society**, New York, v. 2014, p. 1-9, 2014.

YU, L.; WANG, S.; LAI, K. K. Credit risk assessment with a multistage neural network ensemble learning approach. **Expert Systems with Applications**, New York, v. 34, n. 2, p. 1434-1444, 2008.


ZHANG, Y. et al. A rule-based model for bankruptcy prediction based on an improved genetic ant colony algorithm. **Mathematical Problems in Engineering**, Cairo, v. 2013, p. 1-10, 2013.

ZHOU, L.; LAI, K. K.; YEN, J. Bankruptcy prediction using SVM models with a new approach to combine features selection and parameter optimisation. **International Journal of Systems Science**, Sheffield, v. 45, n. 3, p. 241-253, 2014.

APÊNDICES

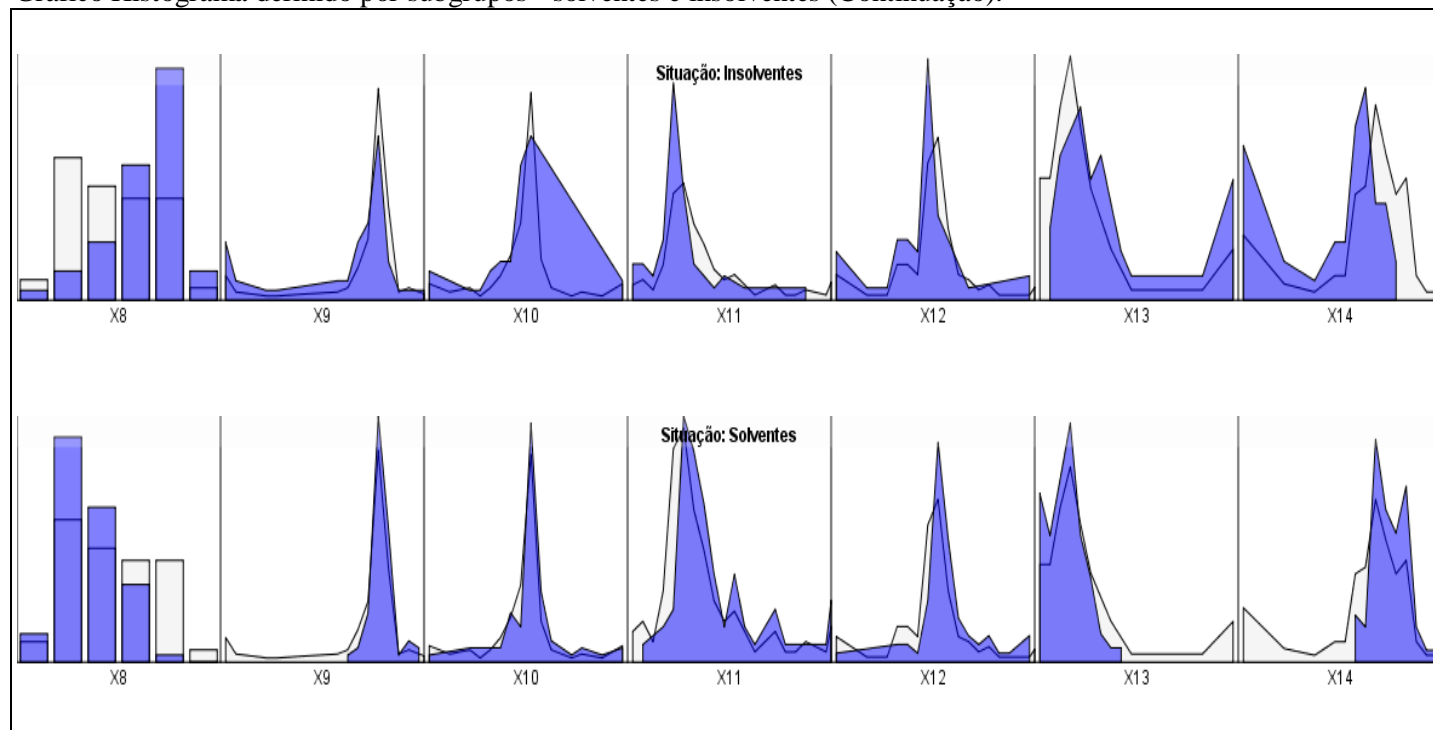
APÊNDICE A – Histograma definido por subgrupos

Gráfico Histograma definido por subgrupos - solventes e insolventes.




“continua”

Gráfico Histograma definido por subgrupos - solventes e insolventes (Continuação).




“continua”

Gráfico Histograma definido por subgrupos - solventes e insolventes (Continuação).




“continua”

Gráfico Histograma definido por subgrupos - solventes e insolventes (Continuação).



“continua”

Gráfico Histograma definido por subgrupos - solventes e insolventes (conclusão).



Fonte: Dados da pesquisa.

APÊNDICE B – Matriz de correlações

Matriz de correlações – Fatorial 01

Variável	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)	(14)	(15)	(16)	(17)	(18)	(19)	(20)	(21)	(22)	(23)	(24)	(25)	(26)	(27)	(28)	(29)	(30)	(31)	(32)	(33)	(34)	(35)					
(1)	1																																							
(2)	0,64	1																																						
(3)	0,81	0,48	1																																					
(4)	0,56	0,64	0,72	1																																				
(5)	0,83	0,58	0,43	0,26	1																																			
(6)	0,57	0,66	0,27	0,25	0,71	1																																		
(7)	-0,85	-0,66	-0,60	-0,43	-0,84	-0,72	1																																	
(8)	-0,72	-0,59	-0,55	-0,46	-0,64	-0,47	0,63	1																																
(9)	0,34	0,33	0,13	0,11	0,40	0,38	-0,38	-0,46	1																															
(10)	0,36	0,41	0,06	-0,03	0,50	0,52	-0,47	-0,50	0,48	1																														
(11)	0,39	0,21	0,48	0,49	0,19	0,11	-0,30	-0,30	0,17	0,07	1																													
(12)	0,54	0,51	0,31	0,18	0,54	0,51	-0,58	-0,58	0,48	0,85	0,41	1																												
(13)	-0,70	-0,42	-0,47	-0,31	-0,77	-0,48	0,77	0,42	-0,23	-0,30	-0,21	-0,35	1																											
(14)	0,98	0,62	0,82	0,55	0,83	0,55	-0,83	-0,67	0,27	0,32	0,39	0,49	-0,70	1																										
(15)	0,62	0,32	0,44	0,23	0,64	0,40	-0,59	-0,47	0,18	0,17	0,21	0,22	-0,55	0,62	1																									
(16)	0,66	0,48	0,47	0,44	0,62	0,32	-0,55	-0,55	0,28	0,31	0,28	0,34	-0,61	0,63	0,41	1																								
(17)	0,16	0,00	0,26	0,01	0,01	0,21	-0,20	-0,05	0,06	0,01	-0,02	0,05	0,00	0,13	0,08	-0,09	1																							
(18)	0,76	0,38	0,56	0,32	0,72	0,40	-0,70	-0,54	0,19	0,20	0,28	0,28	-0,71	0,77	0,87	0,58	0,04	1																						
(19)	0,80	0,47	0,69	0,48	0,71	0,41	-0,71	-0,52	0,17	0,15	0,35	0,28	-0,73	0,85	0,64	0,59	-0,06	0,83	1																					
(20)	-0,02	0,00	-0,01	-0,03	0,00	-0,01	0,08	-0,19	0,20	0,10	-0,01	0,06	0,02	-0,05	0,16	0,14	0,12	0,08	-0,12	1																				
(21)	0,82	0,60	0,62	0,46	0,71	0,51	-0,69	-0,75	0,38	0,47	0,38	0,62	-0,50	0,75	0,47	0,73	0,10	0,59	0,55	0,16	1																			
(22)	0,78	0,56	0,53	0,34	0,73	0,57	-0,67	-0,75	0,39	0,50	0,30	0,59	-0,47	0,72	0,48	0,68	0,10	0,59	0,54	0,15	0,94	1																		
(23)	0,74	0,48	0,59	0,47	0,61	0,34	-0,56	-0,56	0,30	0,25	0,29	0,40	-0,51	0,67	0,39	0,77	0,17	0,53	0,54	0,07	0,79	0,77	1																	
(24)	0,44	0,20	0,25	0,14	0,48	0,41	-0,38	-0,47	0,26	0,28	0,18	0,25	-0,31	0,40	0,69	0,41	0,14	0,61	0,37	0,28	0,50	0,56	0,45	1																
(25)	0,50	0,34	0,33	0,41	0,48	0,59	-0,57	-0,34	0,17	0,10	0,23	0,11	-0,45	0,48	0,64	0,34	0,21	0,67	0,52	0,09	0,37	0,40	0,31	0,57	1															
(26)	-0,83	-0,50	-0,70	-0,50	-0,74	-0,41	0,72	0,55	-0,19	-0,20	-0,37	-0,33	0,77	-0,87	-0,59	-0,70	0,06	-0,79	-0,96	0,12	-0,60	-0,57	-0,59	-0,33	-0,45	1														
(27)	-0,44	-0,24	0,41	-0,31	-0,41	-0,13	0,25	0,38	-0,07	-0,09	-0,29	-0,18	0,34	-0,48	-0,38	-0,46	0,38	-0,45	-0,48	-0,06	-0,38	-0,36	-0,29	-0,20	-0,14	0,51	1													
(28)	-0,02	-0,03	0,09	0,07	-0,10	-0,11	0,05	0,12	0,01	-0,12	-0,04	-0,09	0,03	-0,06	-0,08	0,14	0,24	-0,05	0,00	-0,17	-0,02	-0,02	0,39	0,04	-0,11	-0,05	0,35	1												
(29)	0,21	0,13	0,27	0,20	0,06	0,05	-0,17	0,03	-0,26	-0,19	0,10	-0,10	-0,12	0,24	0,03	-0,06	-0,05	0,15	0,38	-0,57	-0,07	-0,05	0,00	-0,13	0,08	-0,30	0,01	0,08	1											
(30)	0,10	0,06	0,13	0,12	0,03	0,03	-0,12	0,10	-0,31	-0,22	0,05	-0,19	-0,11	0,15	0,11	-0,02	-0,12	0,17	0,35	-0,48	-0,13	-0,13	-0,18	-0,10	0,12	-0,29	-0,07	-0,12	0,87	1										
(31)	0,83	0,50	0,70	0,50	0,74	0,41	-0,72	-0,55	0,19	0,20	0,37	0,34	-0,77	0,87	0,59	0,71	-0,06	0,79	0,96	-0,12	0,60	0,57	0,59	0,33	0,45	-1,00	-0,51	0,04	0,30	0,29	1									
(32)	0,28	0,13	0,47	0,35	0,02	0,03	-0,26	-0,17	0,07	0,03	0,28	0,23	-0,11	0,24	0,10	0,16	0,34	0,11	0,11	0,03	0,36	0,12	0,34	0,04	0,06	-0,12	0,11	0,32	0,00	-0,08	0,12	1								
(33)	0,51	0,36	0,29	0,18	0,53	0,37	-0,39	-0,54	0,24	0,38	0,24	0,43	-0,25	0,47	0,30	0,54	-0,07	0,38	0,32	0,14	0,74	0,76	0,54	0,45	0,24	-0,37	-0,32	-0,05	-0,08	-0,06	0,37	0,10	1							
(34)	0,47	0,28	0,34	0,18	0,44	0,30	-0,34	-0,45	0,16	0,19	0,18	0,29	-0,13	0,44	0,27	0,34	0,08	0,33	0,31	0,05	0,57	0,59	0,46	0,34	0,22	-0,31	-0,21	0,09	0,04	0,01	0,32	0,19	0,87	1						
(35)	0,48	0,26	0,35	0,20	0,42	0,29	-0,32	-0,43	0,18	0,16	0,17	0,27	-0,14	0,42	0,26	0,34	0,24	0,31	0,27	0,02	0,53	0,59	0,59	0,39	0,24	-0,26	-0,11	0,25	0,05	-0,07	0,27	0,19	0,71	0,86	1					

a. Determinante = 5,682E-26

Para se obter uma boa análise fatorial, a significância da determinante deve apresentar valores próximos de 0. (CORRAR et al., 2014, p. 100). Determinante = 5,682E-26

Matriz de Correlação anti-imagem – Fatorial 01

Variável	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)	(14)	(15)	(16)	(17)	(18)	(19)	(20)	(21)	(22)	(23)	(24)	(25)	(26)	(27)	(28)	(29)	(30)	(31)	(32)	(33)	(34)	(35)						
(1)	.931 ^a																																								
(2)	-.078	.779 ^a																																							
(3)	-.323	.272	.812 ^a																																						
(4)	.165	-.610	-.519	.713 ^a																																					
(5)	-.149	.316	.604	-.150	.883 ^a																																				
(6)	.005	-.599	-.038	.290	-.356	.779 ^a																																			
(7)	.020	.215	.104	-.108	.198	.010	.926 ^a																																		
(8)	.093	.062	.003	.275	.165	.127	-.125	.910 ^a																																	
(9)	-.255	-.026	-.015	.020	-.114	.047	.071	.154	.862 ^a																																
(10)	.097	.088	.024	.041	.027	-.019	-.007	.189	-.149	.697 ^a																															
(11)	.033	.305	.075	-.284	.129	.024	.060	-.043	.166	.530	.689 ^a																														
(12)	-.131	-.145	.053	.051	.028	.047	.133	-.073	.072	-.834	.638	.770 ^a																													
(13)	.101	-.106	.158	.024	.297	.009	-.415	.197	-.023	-.062	.091	.028	.869 ^a																												
(14)	-.575	-.122	-.282	-.069	-.414	.004	.048	-.260	.285	-.206	.126	.170	-.233	.896 ^a																											
(15)	-.019	-.262	-.237	.220	-.356	.199	.026	-.006	.034	.025	.086	.030	-.235	.102	.854 ^a																										
(16)	.014	-.122	.026	.019	.021	.082	.173	-.030	-.002	-.368	.200	.397	.023	.092	.152	.882 ^a																									
(17)	.155	.017	-.411	.310	-.009	.199	.090	.085	.045	-.101	.086	.113	-.014	-.049	.073	.200	.428 ^a																								
(18)	-.098	-.132	.113	.245	.146	.333	-.036	.118	.090	-.001	.005	-.027	.343	-.105	-.500	.060	-.031	.901 ^a																							
(19)	.177	-.148	-.048	.050	-.064	.125	.079	-.206	-.205	.071	.048	.118	-.194	-.035	.104	.322	.146	-.279	.923 ^a																						
(20)	.060	.120	-.147	.066	-.047	.007	.289	.116	-.052	.057	.014	-.073	.161	.031	-.094	.227	-.115	.010	-.155	.687 ^a																					
(21)	-.245	-.226	.105	-.222	-.190	.215	-.119	-.164	.074	-.046	.017	-.020	.013	.282	.026	-.087	-.095	.035	.043	.060	.836 ^a																				
(22)	.110	.229	-.246	.271	.118	.323	.181	.271	.009	.084	.034	-.036	-.159	.130	.025	.024	.135	.046	-.153	-.044	.846	.820 ^a																			
(23)	-.155	.002	.258	-.121	.014	.216	-.060	-.059	.014	.226	.151	-.146	.142	-.117	.014	.414	-.276	.120	-.139	-.008	-.108	-.096	.868 ^a																		
(24)	.034	.268	.045	-.091	.104	.249	-.113	.210	-.009	.092	.046	.046	.037	-.089	-.372	.017	.022	.056	-.139	-.073	-.058	.051	.080	.899 ^a																	
(25)	-.178	.491	.312	-.631	.261	.611	.224	-.161	.011	-.046	.026	.132	-.137	.138	-.163	.070	-.160	.435	-.094	-.035	.077	-.005	.067	-.015	.733 ^a																
(26)	-.118	.015	.103	.127	.101	.186	.000	.031	-.217	.264	.174	-.220	.345	.226	.194	.116	-.162	.086	.258	-.083	.156	.124	.050	-.086	.073	.854 ^a															
(27)	-.121	-.132	.409	-.034	.144	.298	.175	-.049	-.016	-.029	.040	.057	.128	-.074	.078	.132	-.395	.200	-.012	-.149	.026	-.158	.324	-.082	-.184	.032	.775 ^a														
(28)	.030	-.087	-.137	-.121	-.120	.122	-.026	-.298	.052	-.144	.043	.107	-.178	.355	-.083	.021	.012	.187	.251	.177	.392	-.270	.492	-.152	.273	-.094	-.389	.305 ^a													
(29)	-.130	-.059	-.219	.173	-.041	.018	-.080	.199	.091	-.047	.092	.004	-.001	.010	.269	.258	.268	.018	-.206	.144	.041	.035	.302	.063	-.089	.104	-.199	-.178	.564 ^a												
(30)	.010	.057	.227	-.202	.076	.074	.115	-.194	.051	.031	.069	.043	-.020	.088	-.281	.285	-.264	.025	.045	.041	.016	-.029	.341	-.061	.162	-.196	.137	.215	-.889	.532 ^a											
(31)	-.121	.035	.098	.132	.106	.174	-.021	.069	-.206	.286	.180	-.247	-.313	.255	.194	.170	-.168	.070	.158	-.061	-.173	.151	.072	-.064	-.074	.993	.032	-.146	.135	-.221	.851 ^a										
(32)	.146	.319	-.230	.150	.185	.251	.174	-.193	-.038	.152	.079	-.165	-.064	-.209	.057	.032	.081	.001	-.121	-.032	.795	.796	-.059	.112	.001	.221	-.190	-.357	.125	-.149	.254	.400 ^a									
(33)	.171	-.101	.005	.062	-.013	.053	.216	-.129	-.034	-.186	.193	.085	.214	.054	.020	.074	.129	.044	.234	.055	-.062	-.233	.094	-.178	.082	.025	-.024	.197	.010	-.094	.006	-.029	.845 ^a								
(34)	-.064	.049	-.032	.066	.001	.003	.264	.124	.012	.160	.140	-.026	-.299	.056	.118	.142	.044	.094	.069	-.155	-.128	.270	.209	.128	.000	.109	.063	-.264	.075	-.038	.113	.075	-.774	.742 ^a							
(35)	-.120	-.020	.029	-.096	-.114	.044	.258	.000	.037	.002	.031	-.082	.135	.129	-.090	.122	-.221	.104	-.126	.174	.295	-.267	-.239	-.054	-.013	-.076	-.027	.105	-.040	.034	-.058	.134	.201	-.675	.812 ^a						

a. Medidas de adequação de amostragem (MSA)

Matriz de correlações – Fatorial 02

Variavel	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(10)	(12)	(13)	(14)	(15)	(16)	(18)	(19)	(21)	(22)	(23)	(24)	(25)	(26)	(29)	(30)	(31)	(33)	(34)	(35)	
(1)	1																												
(2)	0,64	1																											
(3)	0,81	0,48	1																										
(4)	0,56	0,64	0,72	1																									
(5)	0,83	0,58	0,43	0,26	1																								
(6)	0,57	0,66	0,27	0,25	0,71	1																							
(7)	-0,85	-0,66	-0,60	-0,43	-0,84	-0,72	1																						
(8)	-0,72	-0,59	-0,55	-0,46	-0,64	-0,47	0,63	1																					
(10)	0,36	0,41	0,06	-0,03	0,50	0,52	-0,47	-0,50	1																				
(12)	0,54	0,51	0,31	0,18	0,54	0,51	-0,58	-0,58	0,85	1																			
(13)	-0,70	-0,42	-0,47	-0,31	-0,77	-0,48	0,77	0,42	-0,30	-0,35	1																		
(14)	0,98	0,62	0,82	0,55	0,83	0,55	-0,83	-0,67	0,32	0,49	-0,70	1																	
(15)	0,62	0,32	0,44	0,23	0,64	0,40	-0,59	-0,47	0,17	0,22	-0,55	0,62	1																
(16)	0,66	0,48	0,47	0,44	0,62	0,32	-0,55	-0,55	0,31	0,34	-0,61	0,63	0,41	1															
(18)	0,76	0,38	0,56	0,32	0,72	0,40	-0,70	-0,54	0,20	0,28	-0,71	0,77	0,87	0,58	1														
(19)	0,80	0,47	0,69	0,48	0,71	0,41	-0,71	-0,52	0,15	0,28	-0,73	0,85	0,64	0,59	0,83	1													
(21)	0,82	0,60	0,62	0,46	0,71	0,51	-0,69	-0,75	0,47	0,62	-0,50	0,75	0,47	0,73	0,59	0,55	1												
(22)	0,78	0,56	0,53	0,34	0,73	0,57	-0,67	-0,75	0,50	0,59	-0,47	0,72	0,48	0,68	0,59	0,54	0,94	1											
(23)	0,74	0,48	0,59	0,47	0,61	0,34	-0,56	-0,56	0,25	0,40	-0,51	0,67	0,39	0,77	0,53	0,54	0,79	0,77	1										
(24)	0,44	0,20	0,25	0,14	0,48	0,41	-0,38	-0,47	0,28	0,25	-0,31	0,40	0,69	0,41	0,61	0,37	0,50	0,56	0,45	1									
(25)	0,50	0,34	0,33	0,41	0,48	0,59	-0,57	-0,34	0,10	0,11	-0,45	0,48	0,64	0,34	0,67	0,52	0,37	0,40	0,31	0,57	1								
(26)	-0,83	-0,50	-0,70	-0,50	-0,74	-0,41	0,72	0,55	-0,20	-0,33	0,77	-0,87	-0,59	-0,70	-0,79	-0,96	-0,60	-0,57	-0,59	-0,33	-0,45	1							
(29)	0,21	0,13	0,27	0,20	0,06	0,05	-0,17	0,03	-0,19	-0,10	-0,12	0,24	0,03	-0,06	0,15	0,38	-0,07	-0,05	0,00	-0,13	0,08	-0,30	1						
(30)	0,10	0,06	0,13	0,12	0,03	0,03	-0,12	0,10	-0,22	-0,19	-0,11	0,15	0,11	-0,02	0,17	0,35	-0,13	-0,13	-0,18	-0,10	0,12	-0,29	0,87	1					
(31)	0,83	0,50	0,70	0,50	0,74	0,41	-0,72	-0,55	0,20	0,34	-0,77	0,87	0,59	0,71	0,79	0,96	0,60	0,57	0,59	0,33	0,45	-1,00	0,30	0,29	1				
(33)	0,51	0,36	0,29	0,18	0,53	0,37	-0,39	-0,54	0,38	0,43	-0,25	0,47	0,30	0,54	0,38	0,32	0,74	0,76	0,54	0,45	0,24	-0,37	-0,08	0,37	0,37	1			
(34)	0,47	0,28	0,34	0,18	0,44	0,30	-0,34	-0,45	0,19	0,29	-0,13	0,44	0,27	0,34	0,33	0,31	0,57	0,59	0,46	0,34	0,22	-0,31	0,04	0,01	0,32	0,87	1		
(35)	0,48	0,26	0,35	0,20	0,42	0,29	-0,32	-0,43	0,16	0,27	-0,14	0,42	0,26	0,34	0,31	0,27	0,53	0,59	0,59	0,39	0,24	-0,26	0,05	-0,07	0,27	0,71	0,86	1	

a. Determinante = 2,167E-22

Matriz de Correlação anti-imagem – Fatorial 02

Variavel	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(10)	(12)	(13)	(14)	(15)	(16)	(18)	(19)	(21)	(22)	(23)	(24)	(25)	(26)	(29)	(30)	(31)	(33)	(34)	(35)			
(1)	.934 ^a																														
(2)	-0,14	.779 ^a																													
(3)	-0,27	0,44	.806 ^a																												
(4)	0,12	-0,70	-0,49	.685 ^a																											
(5)	-0,21	0,29	0,74	-0,19	.869 ^a																										
(6)	0,08	-0,60	-0,29	0,42	-0,40	.769 ^a																									
(7)	0,02	0,17	0,13	-0,17	0,13	0,07	.939 ^a																								
(8)	0,12	0,04	0,09	0,23	0,18	-0,13	-0,10	.946 ^a																							
(10)	0,08	-0,14	-0,02	0,26	-0,06	0,00	0,01	0,21	.782 ^a																						
(12)	-0,16	0,13	0,13	-0,20	0,15	-0,12	0,20	-0,06	-0,75	.817 ^a																					
(13)	0,12	-0,03	0,16	-0,05	0,33	-0,08	-0,41	0,15	-0,05	-0,03	.872 ^a																				
(14)	-0,59	-0,06	-0,38	-0,03	-0,39	0,02	0,05	-0,22	-0,10	0,10	-0,21	.926 ^a																			
(15)	0,00	-0,25	-0,31	0,21	-0,38	0,19	0,00	-0,02	0,10	-0,06	-0,28	0,13	.831 ^a																		
(16)	0,00	-0,07	0,05	-0,11	0,00	0,09	0,07	0,01	-0,29	0,32	0,03	0,11	0,10	.898 ^a																	
(18)	-0,07	-0,13	0,06	0,26	0,13	0,31	-0,07	0,07	-0,01	-0,03	0,32	-0,08	-0,55	-0,09	.907 ^a																
(19)	0,14	-0,14	-0,02	0,04	-0,08	0,18	0,01	-0,08	0,01	0,03	-0,16	-0,09	0,10	0,26	-0,26	.947 ^a															
(21)	-0,22	0,00	-0,11	-0,11	-0,03	0,10	0,08	0,00	0,11	-0,25	-0,05	0,14	0,01	-0,12	-0,01	-0,08	.919 ^a														
(22)	-0,01	-0,03	-0,07	0,23	-0,05	-0,20	0,04	0,21	-0,02	0,15	-0,18	0,04	0,11	0,04	-0,09	-0,13	-0,60	.903 ^a													
(23)	-0,10	0,00	0,04	-0,06	-0,02	0,06	0,02	-0,24	0,13	-0,01	0,03	0,06	-0,02	-0,47	0,01	0,05	-0,25	-0,04	.883 ^a												
(24)	0,03	0,27	0,08	-0,13	0,12	-0,26	-0,11	0,17	-0,13	0,07	0,03	-0,03	-0,40	-0,01	-0,06	-0,11	0,06	-0,06	-0,18	.896 ^a											
(25)	-0,19	0,54	0,41	-0,64	0,34	-0,65	0,29	-0,09	-0,07	0,23	-0,05	0,04	-0,13	-0,01	-0,40	-0,15	0,04	0,01	0,07	0,00	.714 ^a										
(26)	-0,19	-0,13	0,07	0,24	0,03	0,24	-0,05	0,06	0,17	-0,12	-0,35	-0,14	0,25	-0,08	-0,08	0,32	0,03	-0,05	0,00	-0,13	-0,13	.855 ^a									
(29)	-0,20	-0,08	-0,08	0,04	-0,02	0,09	-0,01	0,06	-0,05	-0,02	-0,07	0,10	0,29	0,32	-0,04	-0,15	0,28	-0,14	-0,45	0,01	0,00	0,19	.496 ^a								
(30)	0,08	0,11	0,14	-0,10	0,10	-0,14	0,12	-0,11	0,04	0,09	0,02	-0,04	-0,28	-0,29	0,04	0,03	-0,23	0,18	0,50	0,01	0,09	-0,23	-0,90	.465 ^a							
(31)	-0,20	-0,12	0,07	0,24	0,03	0,23	-0,06	0,07	0,18	-0,14	-0,33	-0,16	0,25	-0,14	-0,07	0,23	0,06	-0,05	-0,01	-0,11	-0,12	0,99	0,21	-0,25	.858 ^a						
(33)	0,15	-0,03	0,11	-0,03	-0,01	0,10	-0,30	-0,09	-0,06	-0,11	0,25	-0,15	0,01	-0,18	0,08	0,16	-0,14	-0,41	0,10	-0,15	-0,10	0,09	0,02	-0,12	0,08	.826 ^a					
(34)	-0,06	-0,03	-0,09	0,09	-0,04	-0,02	0,28	0,07	0,08	0,11	-0,35	0,06	0,10	0,16	-0,14	-0,02	-0,09	0,38	0,10	0,09	0,07	0,08	0,05	0,03	0,07	-0,78	.740 ^a				
(35)	-0,08	0,04	-0,04	-0,03	-0,06	0,00	-0,18	0,02	0,01	-0,11	0,13	0,08	-0,07	-0,04	0,13	-0,09	0,29	-0,25	-0,37	-0,04	-0,08	-0,07	-0,01	-0,04	-0,05	0,24	-0,70	.815 ^a			

a. Medidas de adequação de amostragem (MSA)

APÊNDICE C – Classificação dos Grupos

Classificação dos Grupos

Empresas	Grupo Original	Grupo Classificado		
		Análise Discriminante	Regressão Logística	Redes Neurais MLP
AES Elpa	0	0	0	0
Aliperti	0	0	0	0
Alpargatas	0	0	0	0
Arezzo Co	0	0	0	0
Azevedo	0	0	0	0
Bompreco	0	0	0	0
Cacique	0	0	0	0
Cedro	0	0	0	0
Ceg	0	0	1	0
Celesc	0	0	0	0
Celpe	0	0	0	0
Cemat	0	0	0	0
Coteminas	0	0	0	0
Cremer	0	0	0	0
Dixie Toga	0	0	0	0
Dohler	0	0	0	0
Electrolux	0	0	0	0
Elekeiroz	0	0	0	1
Energias BR	0	0	0	0
Eternit	0	0	0	0
Evora	0	0	0	0
Ferbasa	0	0	0	0
Fertibras	0	0	0	0
Fibria	0	0	0	0
Forja Taurus	0	0	0	0
Fras-Le	0	0	0	0
Gol	0	0	0	0
Guararapes	0	0	0	0

“continua”

Classificação dos Grupos “continuação”

Empresas	Grupo Original	Grupo Classificado		
		Análise Discriminante	Regressão Logística	Redes Neurais MLP
Habitasul	0	0	0	0
Iguacu Cafe	0	0	0	0
Ind Cataguas	0	0	0	0
Itausa	0	0	0	0
Itautec	0	0	0	0
Josapar	0	0	0	0
Karsten	0	0	0	0
Klabin S/A	0	0	1	0
Kroton	0	0	0	0
Le Lis Blanc	0	0	0	0
Leco	0	0	0	0
Lix da Cunha	0	0	0	0
Lojas Renner	0	0	0	0
Magnesita SA	0	0	0	0
Marisol	0	0	0	0
Mendes Jr	0	1	1	0
Metal Iguacu	0	1	1	0
Mills	0	0	0	0
Minasmaquinas	0	0	0	0
Petrobras	0	0	0	0
Pettenati	0	0	0	0
Plascar Part	0	0	0	0
Polialden	0	0	0	0
Pronor	0	0	0	0
Randon Part	0	0	0	0
Rasip Agro	0	0	0	0
Renar	0	0	0	0
Riosulense	0	0	0	0
SLC Agricola	0	0	0	0
Sondotecnica	0	0	0	0
Springer	0	0	0	0

“continua”

Classificação dos Grupos “continuação”

Empresas	Grupo Original	Grupo Classificado		
		Análise Discriminante	Regressão Logística	Redes Neurais MLP
Springs	0	0	0	0
Tam S/A	0	0	1	0
Tekno	0	0	0	0
Tractebel	0	0	0	0
Trafo	0	0	0	0
Trevisa	0	0	0	0
Tupy	0	0	0	0
V-Agro	0	0	0	0
Vicunha Text	0	0	0	0
Wembley	0	0	0	0
Wetzel S/A	0	0	1	0
Agrenco	1	0	1	1
Aquatec	1	1	1	1
Bombril	1	1	1	1
Botucatu Tex	1	1	1	1
Buettner	1	1	1	1
Celpa	1	1	1	1
Chapeco	1	1	1	1
Chiarelli	1	1	1	1
Clarion	1	1	1	1
Const Beter	1	1	1	1
Copas	1	1	1	1
Corbetta	1	1	1	1
DHB	1	1	1	1
Eneva	1	1	1	1
Eucatex	1	0	1	1
Fab C Renault	1	1	1	1
Fibam	1	0	0	1
Gp Invest	1	0	0	1
GPC Part	1	1	1	1
IDEIASNET S.A.	1	0	1	1

“continua”

Classificação dos Grupos “conclusão”

Empresas	Grupo Original	Grupo Classificado		
		Análise Discriminante	Regressão Logística	Redes Neurais MLP
IGB S/A	1	1	1	1
Inbrac	1	1	1	1
Inepar	1	1	1	1
Kepler Weber	1	1	1	1
Lark Maqs	1	1	1	1
Lojas Arapua	1	1	1	1
Lupatech	1	1	1	1
Mangels Indl	1	1	1	1
Mesbla	1	1	1	1
Met Duque	1	1	1	1
Minupar	1	1	1	1
MMX Miner	1	1	1	1
Montreal	1	0	0	1
OGX Petroleo	1	1	1	1
OSX Brasil	1	1	1	1
Parmalat	1	1	1	1
Pet Manguinh	1	1	1	1
Recrusul	1	1	1	1
Rede Energia	1	1	1	1
Sansuy	1	0	0	1
Schlosser	1	1	1	1
Sharp	1	1	1	1
Spscs Industrial	1	0	1	1
Sultepa	1	1	1	1
Sv Engenhar	1	1	1	1
Tecel S Jose	1	1	1	1
Tecnosolo	1	0	0	0
Teka	1	1	1	1
Tex Renaux	1	1	1	1
Varig Transp	1	1	1	1
Vasp	1	1	1	1

* “1” Insolvente, “0” Solvente