



Serviço Público Federal
Ministério da Educação
Fundação Universidade Federal de Mato Grosso do Sul



ESCOLA DE ADMINISTRAÇÃO E NEGÓCIOS

MESTRADO EM CIÊNCIAS CONTÁBEIS

ELOIR DE OLIVEIRA GONDRIGE

**Estatística Multivariada Aplicada: Construção do Modelo de Previsão de Insolvência
Aranha & Gondrige**

Linha de Pesquisa: Contabilidade Societária e Finanças

CAMPO GRANDE/MS 2021

ELOIR DE OLIVEIRA GONDRIGE

**Estatística Multivariada Aplicada: Construção do Modelo de Previsão de Insolvência
Aranha & Gondrige**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Contábeis (PPGCC) da Escola de Administração e Negócios (ESAN) da Universidade Federal de Mato Grosso do Sul (UFMS) como requisito parcial à obtenção do título de Mestre em Ciências Contábeis.

Orientador: Prof. Dr. José Aparecido Moura Aranha

Linha de Pesquisa: Contabilidade Societária e Finanças

CAMPO GRANDE/MS 2021

AGRADECIMENTOS

Antes de tudo a Deus, por iluminar meus caminhos e me conceder sabedoria e forças para prosseguir, sempre.

Ao meu orientador, Prof. Dr. José Aparecido Moura Aranha, pela leitura atenta da dissertação, pela orientação dedicada, confiança e competência, pelo exemplo de compromisso com a pesquisa científica e total apoio para a realização dessa pesquisa!

Ao Prof. Dr. Luiz Miguel Renda dos Santos, Universidade Federal de Mato Grosso do Sul (UFMS), Profa. Dra. Eloir Trindade Vasques Vieira, Universidade Católica Dom Bosco (UCDB), pelas contribuições na fase de qualificação e, em seguida, na defesa desta Dissertação!

Aos docentes do Programa de Pós-Graduação em Ciências Contábeis PPGCC da UFMS, pelo suporte e ensinamentos dado no transcorrer das disciplinas do curso!

Aos servidores da Secretária, suporte técnico e demais colaboradores da instituição que contribuíram para realização desta pesquisa.

Aos meus pais, Lair Gondrige (in memorian), e Helena Gondrige, com todo meu amor e gratidão pelo apoio logístico e por tudo que fizeram ao longo de minha formação. A minha irmã Eliane Gondrige, pela colaboração e compreensão nesse período em que estive ausente; minha irmã Fabiana Gondrige, que sempre torceu pelo meu sucesso, e um agradecimento em especial ao meu irmão Enalto Gondrige, por sempre dar apoio e incentivos aos meus estudos: você serviu de um grande exemplo na minha trajetória!

Especialmente, à minha esposa Laudicéa Gondrige, uma grande mulher e meu maior tesouro, agradeço por toda compreensão durante essa fase e pelo incentivo na minha jornada de estudo, em todas as etapas me ajudou e contribuiu para que eu pudesse concluir meus projetos. Aos meus amados filhos Lauany Gondrige e Lucas Eduardo Gondrige!

Aos colegas de mestrado em contabilidade da UFMS, pelo companheirismo e amizade durante as aulas.

A todos que, direta ou indiretamente, contribuíram para o desenvolvimento desta pesquisa, meu muito obrigado.

RESUMO

A previsão de insolvência, embora seja assunto bastante discutido, ainda apresenta uma necessidade de aprimoramento dos modelos existentes, devido ao surgimento de novas variáveis preditoras, como várias substituições de moedas, cenários econômicos, adequações das normas de contabilidade com o padrão internacional, dentre outros fatores que afetam a economia e o desempenho das companhias. A mensuração da insolvência conjectura-se como uma das inúmeras dificuldades às quais as organizações estão suscetíveis, em que a análise das demonstrações contábeis auxilia na obtenção das informações sobre o desempenho econômico-financeiro das companhias. Dessa forma, indaga-se como construir um modelo de previsão de insolvência com a aplicação da função discriminante? O objetivo deste trabalho visou desenvolver empiricamente um modelo de previsão de insolvência utilizando a análise discriminante. O trabalho se justifica pela necessidade de buscar compreender a situação financeira das companhias e a transição que ocorre entre as empresas solventes e insolventes para que possa servir de orientação em previsões financeiras. Para o desenvolvimento do modelo, foram utilizadas duas amostras com 30 companhias sendo cada uma constituída por empresas insolventes por se encontrarem em recuperação judicial, que apresentam prejuízos recorrentes ou com Passivo a Descoberto a outra amostra composta por empresas solventes. Foram levados em consideração, para efeito de homogeneidade entre os grupos de amostras, companhias de um mesmo segmento bem como volumes de ativo similares. Foram coletados indicadores econômico-financeiros junto à base de dados da Economática[®] relativos ao ano de 2019. Para modelagem da função discriminante, foi utilizado o Software *IBM SPSS Estatistics* bem como planilha *Microsoft Excel*[®]. A pesquisa, quanto à sua natureza, caracteriza-se como aplicada; quanto à abordagem, é quantitativa; com relação aos objetivos, classifica-se como descritiva e utiliza-se dos métodos de pesquisa bibliográfica e coleta de dados. Estatisticamente o modelo desenvolvido apresenta um poder discriminatório de 90% e, quando submetido ao teste de validação, utilizando amostra de empresas diferentes das utilizadas inicialmente, apresentou índice de acerto de 95%. No teste comparativo com outros modelos existentes, o resultado foi de 93,33%, portanto, o Modelo de previsão de Insolvência Aranha & Gondrigo obteve uma representatividade excelente, sendo considerado um modelo robusto.

Palavras-chave: Análise Financeira, Função Discriminante, Previsão de Falência.

ABSTRACT

The insolvency forecast, although it is a widely discussed subject, still presents a need to improve the existing models, due to the emergence of new predictor variables, such as several currency substitutions, economic scenarios, adaptations of accounting standards with the international standard, among others factors that affect the economy and performance of companies. The measurement of insolvency is conjectured as one of the countless difficulties to which organizations are susceptible, in which the analysis of financial statements helps to obtain information about the economic and financial performance of companies. Thus, one asks how to build an insolvency prediction model with the application of the discriminant function? The aim of this work was to empirically develop an insolvency prediction model using discriminant analysis. The work is justified by the need to seek to understand the financial situation of companies and the transition that occurs between solvent and insolvent companies so that it can serve as guidance in financial forecasts. For the development of the model, two samples with 30 companies were used, each consisting of insolvent companies because they are in judicial recovery, which have recurring losses or with Liabilities Uncovered to another sample composed of solvent companies. For the purpose of homogeneity between sample groups, companies from the same segment as well as similar asset volumes were taken into account. Economic and financial indicators were collected from the Economática® database for the year 2019. For modeling the discriminant function, the IBM SPSS Estatistics Software was used, as well as a Microsoft Excel® spreadsheet. The research, in terms of its nature, characterizes up as applied; as for the approach, it is quantitative; with regard to the objectives, it is classified as descriptive and uses bibliographic research and data collection methods. Statistically, the developed model has a discriminatory power of 90% and, when submitted to the validation test, using a sample of companies different from those used initially, it presented a 95% accuracy rate. In the comparative test with other existing models, the result was 93.33%, therefore, the Aranha & Gondrge Insolvency Prediction Model obtained an excellent representation, being considered a robust model.

Keywords: Financial Analysis, Discriminant Function, Bankruptcy Prediction.

SUMÁRIO

JUSTIFICATIVA	12
1 – INTRODUÇÃO	14
2 – REFERENCIAL TEORICO	15
2.1 – Estudos Anteriores Desenvolvidos no Brasil.....	15
2.2 – Estudos Anteriores Desenvolvidos no Exterior.....	26
2.3 – Análise Econômico-Financeira.....	29
2.3.1 – Liquidez.....	31
2.3.2 – Indicadores de Estrutura de Capital ou Endividamento.....	32
2.3.3 – Indicadores de Rentabilidade	33
2.4 – Análise Discriminante.....	34
2.4.1 – Suposições da Análise Discriminante.....	39
2.5 – Insolvência.....	40
2.5.1 – Evolução Histórica da Lei de Falência ou Insolvência.....	40
3 – PROCEDIMENTOS METODOLÓGICOS	42
4 – DISCUSSÃO DO RESULTADO	59
4.1 – Validação do Modelo Aranha & Gondrige.....	65
4.2 – Comparação com os Modelos Existentes.....	67
5 – CONCLUSÃO	75
6 – REFERÊNCIAS	77

LISTA DE FIGURAS

Figura 01 – Termômetro de Insolvência de Kanitz.....	17
Figura 02 – Resumo de Processamento.....	46
Figura 03 – Teste de Igualdade de Médias de Grupos.....	47
Figura 04 – Matriz de Covariância e Correlação.....	49
Figura 05 – Teste de M de Box.....	50
Figura 06 – Autovalores e Correlação Canônica.....	51
Figura 07 – Resultado do Lambda de Wilks.....	51
Figura 08 – Coeficientes da Função Discriminante.....	52
Figura 09 – Resumo de Processamento de Classificação dos Agrupamentos.....	53
Figura 10 – Resultado da Classificação.....	53
Figura 11 – Resumo de Processamento de Caso de Análise.....	54
Figura 12 – Médias e Desvio-padrão das Variáveis Independentes.....	55
Figura 13 – Teste de Igualdade de Médias de Grupos.....	55
Figura 14 – Matriz de Covariância e Correlação.....	56
Figura 15 – Teste de M de Box.....	56
Figura 16 – Autovalores e Correlação Canônica.....	57
Figura 17 – Resultado do Lambda de Wilks.....	57
Figura 18 – Coeficientes de Função Discriminante Canônica.....	58
Figura 19 – Resumo de Processamento de Classificação.....	58
Figura 20 – Resultados da Classificação.....	59
Figura 21 – Curva de Gauss e os Pontos de Separação do Modelo.....	64

LISTA DE GRÁFICOS

Gráfico 01 – Aplicação dos Modelos de Insolvência na GOL Linhas Aéreas Inteligentes S/A..	23
Gráfico 02 – Aplicação dos Modelos de Insolvência na TAM Linhas Aéreas S/A.....	24

LISTA DE TABELAS

Tabela 01 – Fator Discriminante de Kanitz no Brasil.....	17
Tabela 02 – Faixa de Classificação das Empresas no Modelo de Kanitz.....	17
Tabela 03 – Identificação dos Índices de Liquidez Modelo Kanitz.....	17
Tabela 04 – Fator Discriminante de Altman no Exterior.....	18
Tabela 05 – Faixa de Classificação no Modelo Altman no Exterior.....	18
Tabela 06 – Função Z no Modelo Brasileiro de Altman, Baidya e Dias.....	19
Tabela 07 – Função Z no Modelo Matias.....	20
Tabela 08 – Indicadores de Liquidez.....	31
Tabela 09 – Indicadores de Estrutura de Capital ou Endividamento.....	33
Tabela 10 – Indicadores de Rentabilidade.....	34
Tabela 11 – Histórico do Código das Falências ou Insolvências.....	41
Tabela 12 – Relação de Empresas Solventes, em Recuperação Judicial, com Prejuízos Sistemáticos e com Passivo a Descoberto em 2019.....	44
Tabela 13 – Nomenclaturas das Variáveis Independentes.....	45
Tabela 14 – Médias e Desvio-padrão das Variáveis Independentes.....	46
Tabela 15 – Resultado da Estatística Descritiva para Média Empresas “0” e Média Empresas “1”.....	61
Tabela 16 – Variáveis das Empresas, Escore Discriminante e Classificação Excel [®]	61
Tabela 17 – Média Empresas “0” e Média Empresas “1”.....	63
Tabela 18 – Relação de Empresas Solventes, em Recuperação Judicial, com Prejuízos Sistemáticos e com Passivo a Descoberto em 2019.....	66
Tabela 19 – Variáveis Empresas, Escore Discriminante e Classificação Excel [®]	66
Tabela 20 – Variáveis Independentes na Função Kanitz.....	68
Tabela 21 – Variáveis Independentes na Função de Elizabetsky.....	70

Tabela 22 – Amostra de Variáveis Independentes na Função de Matias.....	71
Tabela 23 – Variáveis Empresas Modelo Altman Função Z_1 e Z_2	73
Tabela 24 – Classificação dos Modelos.....	75

LISTA DE ABREVIATURAS E SIGLAS

Análise Discriminante Linear – ADL

Análise Discriminante Múltipla – MDA

Análise por Envoltória de Dados – DEA

Bolsa, Brasil, Balcão – B3

Capital de Giro – CG

Comissão de Valores Mobiliários – CVM

Estados Unidos da América – EUA

Giro do Ativo – GA

Giro do Patrimônio Líquido – GPL

Grau de Endividamento – GE

Instituto Brasileiro de Geografia e Estatística – IBGE

Imobilização do Capital Próprio – ICP

Liquidez Corrente – LC

Liquidez Geral – LG

Liquidez Seca – LS

Margem Bruta – MB

Margem Líquida – ML

Participação de Capital de Terceiros – PCT

Retorno sobre o Ativo – ROA

Retorno sobre Capital de Terceiro – ROIC

Retorno sobre o Patrimônio Líquido – ROE

Statistical Packages for the Social Sciences – SPSS

JUSTIFICATIVA

O objetivo desta pesquisa é propor um modelo de previsão de insolvência baseado em indicadores contábeis com o uso da análise discriminante. Embora o assunto tenha sido bastante discutido, ainda há uma necessidade de aprimoramento dos modelos existentes, devido ao surgimento de novas variáveis preditoras, como várias substituições de moedas desde os últimos modelos, cenários econômicos, adequações das normas de contabilidade com o padrão internacional, dentre outros fatores que afetam a economia e no desempenho das companhias (SILVA, 2016).

O estudo se localiza no campo das finanças, com enfoque nas contribuições dos modelos de previsão de insolvência, bem como, para os desafios, avanço e possibilidades no ambiente de pesquisas voltadas a esse tema, sendo assim, o modelo a ser proposto terá aplicação em empresas de vários segmentos com o intuito de coadjuvar os gestores na tomada de decisão.

A mensuração da insolvência conjectura-se como uma das inúmeras dificuldades às quais as organizações estão suscetíveis, em que a análise das demonstrações contábeis auxilia na obtenção das informações sobre o desempenho econômico-financeiro das companhias.

Também, é sabido que os modelos de previsão de insolvências estão evidenciados nas literaturas de vários autores, como por exemplo os apresentados por Elizabetsky (1976), Matias (1976), Kanitz (1978), Altman, Baidya e Dias (1979), e Silva (1982).

Sendo assim, Kassai e Onusic (2004, p.1) salientam que “a análise de indicadores extraídos das demonstrações financeiras é elemento importante para a tomada de decisão sobre investimentos e empréstimos, auxiliando na avaliação do grau de solvabilidade de uma empresa”.

Inquestionavelmente a aplicação de modelos de insolvência seja uma ferramenta antiga na avaliação de empresas, mas, ainda se faz necessário enquanto não surgem outros modelos atualizados. Taboada Pinheiro, Santos, Douglas Colauto e Lima Pinheiro (2007) já evidenciavam que de certo modo novos modelos estruturados e com a aplicação de métodos estatísticos surgirão e poderão de alguma forma ser úteis aos gestores.

Torna-se evidente que a utilização de modelos de insolvência nas empresas ainda são um dos elementos que complementam o processo decisório. Sendo assim, com a preocupação de resguardar a solvabilidade das empresas e os interesses dos gestores que atuam no mercado financeiro, Taboada Pinheiro et al. (2007) já alertava aos gestores sobre o uso dos modelos de

previsão de insolvência cuja aplicabilidade seria útil e ajudaria na avaliação da predisposição das empresas à insolvência.

É de grande valia a orientação feita por Pinto (2008), o qual ressaltou que a análise dos dados das empresas em anos anteriores e com o emprego dos modelos de estatísticas multivariadas seria crucial para predizer as tendências do futuro das empresas quanto a sua solvência ou insolvência.

Ao longo do tempo, foram desenvolvidos vários modelos de previsão de insolvência, tanto no exterior como no Brasil, conforme ampla abordagem por parte de Silva (2016).

Desse modo, é possível verificar o trabalho desenvolvido no exterior por Fitz Patrick (1932), como o estudo de Winakor, Smith e Merwin, além do estudo de Tamari e Beaver (1966), Backer e Gosman., assim também o estudo de Altman (1968) que construiu seu modelo com base no uso de instrumentos estatísticos mais evoluídos, como a Análise Discriminante Múltipla.

Do mesmo modo, podem-se citar alguns estudos realizados no Brasil que também possuem o cunho de detectar ou prever situações de insolvência nas empresas. Vale ressaltar o estudo de Altman com empresas brasileiras (1968), bem como o trabalho desenvolvido por Elizabetsky (1976) “Um Modelo Matemático para decisão de Crédito no Banco Comercial”, e de grande marco na literatura o estudo pioneiro com o uso de análise discriminante de Kanitz (1978), conhecido como “Termômetro de Insolvência”. Ressaltam-se também os trabalhos de Matias (1978) o qual se fez valer do uso da técnica estatística de análise discriminante, e de Pereira (1982) que utilizou a ferramenta estatística de análise discriminante.

De acordo com a pesquisa de Guimarães e Belchior (2008), o assunto já foi amplamente discutido, entretanto, há a necessidade de aprimoramento dos modelos existentes, bem como da descoberta de novas variáveis preditoras e técnicas que melhor retratem o comportamento das empresas sob a ótica do risco de crédito, opinião que também é ratificada por Silva (2016).

Ainda salientando o trabalho de Guimarães e Belchior (2008), houve outro destaque em sua pesquisa na qual, em uma análise criteriosa, perceberam que uma variável, que representava todo o recurso próprio disponível da empresa, foi submetida com o uso da discriminante a testes realizados em outros estudos com a utilização de instituições financeiras

e replicados em empresas não financeiras e os resultados foram considerados eficazes para ambas.

No entanto, o modelo proposto por Guimarães e Belchior (2008, p. 176), “apresentou índice de acerto de 88,6%, valor superior a resultados de alguns modelos construídos no passado com mesma técnica”.

Sendo assim, devido ao surgimento de novas variáveis preditoras, troca de moeda, mudança nas legislações entre outros fatores que afetam a economia e refletem no comportamento das companhias, evidencia-se a importância de aprofundar este estudo na criação de um modelo de análise discriminante alinhado com a conjuntura econômica atual e que seja capaz de antever a insolvência das companhias bem como contribuir com o avanço da área de contabilidade e finanças.

1. INTRODUÇÃO

O objetivo deste trabalho é construir um modelo de função capaz de prever insolvência de empresas com o emprego de métodos quantitativos baseados na função discriminante. Cabe acentuar as companhias são entidades com vida própria que buscam a longevidade, conforme o Princípio da Entidade (IUDÍCIBUS, 2010). Dessa forma, conforme dados do IBGE (2017), menos de 38% das empresas sobrevivem após cinco anos de atividade de acordo com os números observados entre os anos de 2010 a 2015.

No contexto brasileiro, observam-se muitas características qualitativa e quantitativa em todas as áreas e seguimentos, portanto, demonstrar através da análise financeira com a utilização dos índices financeiros analisados, ter como resultante uma função discriminante que possa antever o alto índice de insolvência das empresas nos primeiros cinco anos de atividades e oferecer evidências empíricas de que as demonstrações contábeis quando se faz uma análise financeira, podem servir de base, com informações de altíssimo grau de relevância, para se evitar a deterioração dessas empresas.

Sendo assim, este estudo justifica-se pela necessidade de buscar compreender a situação financeira das empresas e a transição que ocorre entre as empresas solventes e insolventes para que possa servir de orientação em previsões financeiras. Tendo como objetivo geral construir um modelo de previsão de insolvência com a utilização dos índices financeiros, em que a resultante será uma função discriminante fornecida pelo software estatístico *IBM SPSS*

Estatistics. Sendo assim, a função discriminante obtida irá classificá-las em duas categorias: empresas solventes e insolventes.

Com base nas considerações tem-se o problema de pesquisa: Como construir um modelo de previsão de insolvência com a aplicação da função discriminante?

Portanto, o objetivo deste trabalho é desenvolver um modelo de previsão de insolvência utilizando a análise discriminante, e como objetivos específicos tem-se:

- a) Selecionar companhias em recuperação judicial, com prejuízos recorrentes e com passivo a descoberto e companhias sem problemas financeiros;
- b) Coletar indicadores financeiros do banco de dados da Economática[®] para compor o modelo de previsão de insolvência;
- c) Construir a função discriminante;
- d) Testar e validar o modelo de previsão de insolvência.

A presente investigação, quanto à natureza, classifica-se como aplicada, possui caráter descritivo quanto aos objetivos (GIL, 2017), quantitativa com relação a sua abordagem e, quanto aos procedimentos, é bibliográfica e documental, pois utilizará da análise de dados primários que serão obtidos pela coleta dos relatórios e demonstrações contábeis das companhias que constituirão a amostra. A amostra para este trabalho será composta de informações econômico-financeiras de 60 companhias de capital aberto que operam na Bolsa, Brasil, Balcão – B3 no ano de 2019, que serão coletadas do banco de dados da Economática[®] e Comissão de Valores Mobiliários (CVM).

O trabalho se subdivide em uma breve introdução, seguindo da parte do referencial teórico baseando na explicação de alguns indicadores financeiros, procedimentos metodológicos da análise discriminante, discussão do resultado, validação da função, comparação do resultado com outros modelos existentes para verificar seu poder discriminatório e a conclusão.

2. REFERENCIAL TEÓRICO

2.1 Estudos Anteriores Desenvolvidos no Brasil

Vários estudos foram realizados com o objetivo de desenvolver modelos capazes de prever insolvência. Os estudos têm início após a crise dos mercados financeiros em consequência do “crash” da Bolsa de Nova York e a Contabilidade manteve seu papel de

geradora de informações, fazendo-se indispensável uma contínua busca pela melhor informação de modo que seja fidedigna e tempestiva.

No Brasil, os estudos iniciados por Kanitz, no início da década de 1970, proporcionaram uma série de publicações, como o artigo de 1974 “Como Prever Falências de Empresas”, tese de livre-docência intitulada “Indicadores Contábeis e Financeiros de Previsão de Insolvência: a experiência da pequena e média empresa brasileira”, bem como o livro “Como Prever Falências”, publicado em 1978 (POUERI, 2002).

Para desenvolver a pesquisa, Kanitz não contava com a tecnologia de *softwares* com a capacidade de processamento como os da atualidade e, possivelmente, nenhuma transparência e fidedignidade nas informações contábeis (POUERI, 2002).

O trabalho pioneiro de Kanitz de 1974 consistiu na elaboração de uma equação matemática com cinco índices econômico-financeiros de balanços, elaborada a partir da técnica de regressão múltipla e análise discriminante (POUERI, 2002).

No entanto, na observação feita por Poueri (2002), Kanitz não obteve êxito em seu modelo, quando aplicado em bancos e empresas comerciais, chegando à conclusão de que sua principal falha foi a utilização de poucos índices extraídos das demonstrações contábeis.

Devido ao crescimento geográfico e do grande volume de recursos transacionados, os intermediadores que participam do mercado financeiro, administradores, gestores, necessitam, cada vez mais, de ferramentas que lhes proporcionem maior controle, agilidade e confiança nas tomadas de decisões. Portanto, a função discriminante poderá ser mais uma ferramenta para compor o rol desses grupos.

Os estudos realizados por Kanitz (1974), no início da década de 1970, foram os primeiros de que se tem conhecimento no Brasil, a respeito da capacidade das demonstrações contábeis de “prever” ou “indicar” problemas de falta solvabilidade das empresas, através da utilização de modelos estatísticos.

Inquestionavelmente, Kanitz (1974) foi pioneiro no uso de análise discriminante no Brasil onde obteve uma resultante que é chamada de “termômetro da insolvência”, como diz Altman (1978, p. 18), apud Kanitz (1974), “no Brasil, Kanitz foi o primeiro pesquisador nessa área e o único de que se tem notícia”.

A seguir, tem-se a fórmula de cálculo do fator de insolvência desenvolvida por Kanitz (1974), bem como os significados na tabela 01:

$$FI = 0,05X_1 + 1,65X_2 + 3,55X_3 - 1,06X_4 + 0,33X_5$$

Tabela 01: Fator Discriminante de Kanitz no Brasil

FI =	fator de insolvência
X ₁ =	lucro líquido / patrimônio líquido
X ₂ =	(ativo circulante + realizável a longo prazo) / exigível total
X ₃ =	(ativo circulante – estoques) / passivo circulante
X ₄ =	ativo circulante / passivo circulante
X ₅ =	exigível total / patrimônio líquido

Fonte: Silva (2016), adaptada pelo Autor, 2021

Assim sendo, Kanitz (1974) atribuiu ao seu modelo três faixas para classificar as empresas: insolvente, solvente e a região da penumbra, isto é, indefinida, conforme tabela 02.

Tabela 02: Faixa de Classificação das Empresas no Modelo de Kanitz

Faixa de solvência	0	e	7
Fator de insolvência	- 3	e	- 7
Região penumbra (indefinida)	0	e	- 3

Fonte: Silva (2016), adaptada pelo Autor, 2021

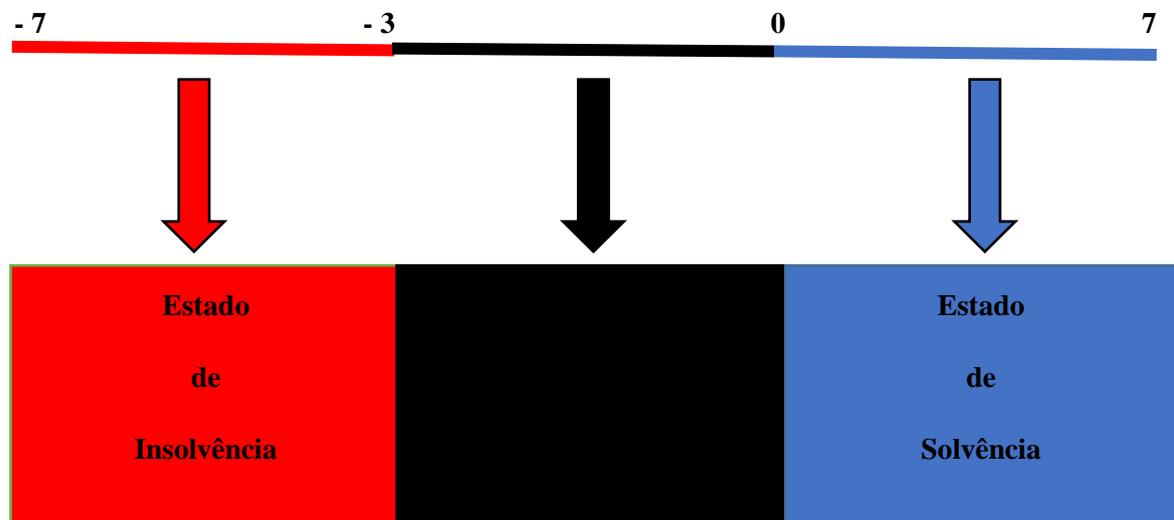


Figura 01: Termômetro de Insolvência de Kanitz

Fonte: o Autor, 2021

Portanto, dentre os cinco índices utilizados por Kanitz (1974), três deles são índices de liquidez, a saber:

Tabela 03: Identificação dos Índices de Liquidez Modelo Kanitz

X₂ = liquidez geral, com peso igual a 1,65

X₃ = liquidez seca, com peso igual a 3,55

X₄ = liquidez corrente, com peso igual a menos 1,06

Fonte: Silva (2016), adaptada pelo Autor, 2021

No estudo realizado no exterior por Altman (1968), com o uso de instrumentos estatísticos, construiu seu modelo com a utilização da análise discriminante múltipla. Ele tentou através desse estudo superar as deficiências das análises baseadas em um único índice. Com o uso de recursos estatísticos, como a análise discriminante multivariada, é possível aplicar a um grupo de índices com capacidade de separar empresas boas (solventes) de empresas ruins (insolventes) e, ao mesmo tempo, determinar o peso relativo de cada índice. Altman, em (1968), desenvolveu a função com a seguinte forma:

$$Z = 0,012X_1 + 0,014X_2 + 0,033X_3 + 0,006X_4 + 0,0999X_5$$

Tabela 04: Fator Discriminante de Altman no Exterior

$X_1 =$	(ativo circulante – passivo circulante) / ativo total
$X_2 =$	lucros retidos / ativo total
$X_3 =$	lucros antes dos juros e impostos / ativo total
$X_4 =$	valor de mercado do <i>equity</i> * / exigível total
$X_5 =$	vendas / ativo total

Fonte: Silva (2016), adaptada pelo Autor, 2021

*valor de mercado do *equity* = número de ações x preço de mercado

Dessa forma, realizadas algumas alterações em seu estudo para superar as deficiências das análises baseadas em um único índice, Altman (1968) obteve o seguinte “score” para a função acima citada:

Tabela 05: Faixa de Classificação no Modelo Altman no Exterior

Grupo das empresas falidas	- 0,29
Grupo das empresas não falidas	5,02

Fonte: Silva (2016), adaptada pelo Autor, 2021

Apesar do estudo de Altman em (1968), realizado nos Estados Unidos, este seguiu a sua pesquisa com intuito de aprimorar a função ou criação de outros modelos. Sendo assim, Altman et al. (1978) desenvolveu um estudo com empresas brasileiras, publicando o trabalho em 1979, “Previsão de problemas financeiros em empresas”, pela Revista de Administração de Empresas (RAE).

Para essa nova pesquisa realizada por Altman et al. (1978), as variáveis explicativas basearam-se no modelo desenvolvido anteriormente pelo próprio Altman, em 1968, nos Estados Unidos, lógico, com algumas mudanças e ajustes devido à necessidade de compatibilização do modelo com os demonstrativos financeiros das empresas brasileiras.

Sendo assim, Altman et al. (1978 p. 22) destaca “nosso procedimento de classificação se baseou no modelo de previsão de insolvência desenvolvido nos EUA por Altman (1968),

que modificamos para compatibilizar com os padrões e práticas usados nas demonstrações financeiras brasileiras”.

A função original desenvolvida por Altman (1968) era da seguinte forma:

$$Z = 1,2 X_1 + 1,4 X_2 + 3,3 X_3 + 0,6 X_4 + 1,0 X_5$$

Posto isso, obtiveram do modelo duas equações, Z_1 e Z_2 . De acordo com Altman et al. (1978), os resultados dos dois modelos, em termos de precisão de classificação, são essencialmente idênticos e, em ambos os casos, o ponto crítico de separação dos grupos é zero.

$$Z_1 = - 1,44 + 4,03 X_2 + 2,25 X_3 + 0,14 X_4 + 0,42 X_5$$

ou

$$Z_2 = - 1,84 - 0,51 X_1 + 6,32 X_3 + 0,71 X_4 + 0,52 X_5$$

Tabela 06: Função Z no Modelo Brasileiro de Altman, Baidya e Dias

$X_1 =$	(ativo circulante – passivo circulante) / ativo total
$X_2 =$	(não exigível – capital aportado pelos acionistas) / ativo total*
$X_3 =$	lucros antes dos juros e impostos / ativo total
$X_4 =$	patrimônio líquido / exigível total**
$X_5 =$	vendas / ativo total

Fonte: Altman et al. (1978), adaptada pelo Autor, 2021

*Não exigível menos capital aportado pelos acionistas é igual a reservas mais lucros acumulados.

** Variável ajustada em relação ao modelo original.

Quanto aos resultados do modelo apresentados por Altman et al. (1978 p. 24), demonstrou ser muito eficiente, “com uma amostra de 58 empresas a precisão do modelo, para dados correspondentes a três, dois e um ano antes da constatação do problema financeiro, teve uma precisão respectivamente de 78%, 84% e 88% na classificação das empresas”.

Destarte, Altman et al. (1978 p. 26) conclui que:

os resultados de nosso estudo, combinando informações publicadas e técnicas estatísticas, são promissores. O modelo desenvolvido a partir de amostras criteriosamente selecionadas demonstrou o poder de classificar firmas (em dois grupos: firmas com características de problema financeiros potenciais e firmas sem indicações de problemas) com precisão da ordem de 88% quando o modelo é aplicado com antecedência de um ano (antes da data de constatação do problema) e com precisão de quase 78% quando o modelo é aplicado a dados com três anos de antecedência.

Na obra de Silva (2016 p. 274), apud Matias (1978), há referência ao trabalho desenvolvido utilizando-se da “técnica estatística de análise discriminante, em que se trabalhou com 100 empresas de diversos ramos de atividade, sendo 50 solventes e 50 insolventes”.

No entanto, para Silva (2016), apud Matias (1978), empresas solventes e insolventes, as primeiras sempre serão as que se beneficiam de crédito amplo e sem restrição no sistema bancário, enquanto as segundas não podem se beneficiar de crédito no sistema bancário como empréstimo, financiamento, logo, nessas condições, só caminharão para a descontinuidade e serão vistas como aquelas que tiveram processo de concordata, requeridas (diferidas), e ou com falência decretada, uma vez que são consideradas insolventes.

O modelo desenvolvido por Matias (1978) com o uso da função discriminante, após testados diversos índices, é:

$$Z = 23,792 X_1 - 8,260 X_2 - 8,868 X_3 - 0,764 X_4 + 0,535 X_5 + 9,912 X_6$$

Tabela 07: Função Z no Modelo Matias

X ₁ =	patrimônio líquido / ativo total
X ₂ =	financiamentos e empréstimos bancários / ativo circulante
X ₃ =	fornecedores / ativo total
X ₄ =	ativo circulante / passivo circulante
X ₅ =	lucro operacional / lucro bruto
X ₆ =	disponível / ativo total

Fonte: Silva (2016), adaptada pelo Autor, 2021

Por conseguinte, Silva (2016), apud Matias (1978) evidenciou no grupo de empresas solventes que 88% foram classificadas corretamente pela função, 2% de forma incorreta e 10% ficaram na região de dúvida. No outro grupo, empresas insolventes, 90% foram classificadas corretamente, 4% erroneamente e 6% ficaram na região de dúvida.

Outros trabalhos foram apontados no estudo realizado por Janot (2001), com eficácia em dois tipos de modelos de *early warning* – o modelo de regressão logística e o modelo de risco proporcional de Cox – utilizados para prever fenômeno de insolvência bancária no Brasil no lapso temporal entre 1995/1998. Referem-se a modelos que produzem estimativas da probabilidade de um banco, com um dado conjunto de características, para que possa sobreviver mais que um determinado intervalo de tempo no futuro, classificando-o como solvente ou insolvente.

Nesses dois modelos citados por Janot (2001), também é possível apontar quais as características mais contribuíram para a insolvência das instituições financeiras. Para Janot (2001, p. 4), os dois modelos estimados obtiveram um “alto percentual de acerto de

classificação dos bancos, com a identificação de uma proporção considerável das insolvências com antecedência, pois indicam que a insolvência nas instituições financeiras é passível de ser prevista no Brasil”. Janot (2001) faz recomendação da utilização de tais modelos pelo Banco Central como instrumento adicional de supervisão do Sistema Financeiro Nacional.

Em pesquisa realizada por Poueri (2002), com a utilização da análise discriminante aplicada em uma amostra de empresas que haviam requerido a concordata, cujo objetivo era verificar se estas poderiam ter algum tipo de êxito com essa solicitação, sendo classificadas em dois grupos - solventes e insolventes - obtendo como produto um modelo de previsão que pode ser considerado híbrido ou misto.

O modelo de Poueri (2002) foi testado quanto à sua capacidade de avaliar se as empresas concluíram suas concordatas e, também, à sua capacidade de discriminar as empresas nos dois grupos anteriormente descritos (solventes e insolventes). Portanto, verificou-se ser possível, através das demonstrações contábeis das empresas objetos do estudo, a previsão da tendência de solvência ou insolvência daquelas, avaliando-se se lograriam êxito com a concordata.

A pesquisa proposta por Castro Junior (2003), com o intuito de analisar a previsão de falência para empresas que atuam no Brasil, usando a análise discriminante linear, regressão logística e redes neurais artificiais tinha por finalidade verificar qual dos modelos melhor classificaria as empresas em solventes e insolventes. Para isso, foi utilizada uma amostra de 40 empresas divididas em dois grupos (solventes e insolventes). Os resultados das provisões obtidas com os modelos foram coerentes com o esperado, ou seja, a análise discriminante teve um desempenho inferior à regressão logística que também foi superada pelas redes neurais artificiais.

Pesquisa realizada por Onusic, Kassai e Viana (2004), com o objetivo de gerar modelos de previsão de insolvência, utilizando análise envoltória de dados (*Data Envelopment Analysis – DEA*) e regressão logística, permitiu os autores compararem os resultados alcançados por essas duas técnicas. Mesmo diante de algumas limitações que ocorreram, os resultados obtidos com os modelos foram considerados satisfatórios, uma vez que o modelo *DEA* classificou corretamente 90% das empresas insolventes e 74% das solventes, enquanto que o de regressão logística foi de 78% para as solventes e 70% de classificação correta para as insolventes.

Ainda no mesmo objetivo da pesquisa desenvolvida em (2004), porém com outros autores para desenvolvimento desta, Onusic, Casa Nova e Almeida (2005), publicado pela RAC, 2ª edição especial (2007), tiveram como propósito desenvolver um modelo de previsão

de insolvência, utilizando uma técnica matemática originada da pesquisa operacional: a análise por envoltória de dados - *DEA*. Com uma amostra composta de 60 empresas divididas em dois grupos, um grupo com 10 empresas que enfrentaram processo de falência/concordata e o outro grupo, composta por 50 empresas solventes, todas do mesmo setor e com porte semelhante.

No modelo *DEA*, desenvolvido por Onusic et al. (2005), foram utilizados alguns parâmetros para que fosse possível classificar as empresas como solventes ou insolventes; uma delas foi a interferência de determinar o ponto de corte. Como resultado, as classificações obtidas pelos indicadores *DEA* foram confrontadas com a situação real da empresa após três anos, e ficou preliminarmente demonstrado que o modelo *DEA* foi capaz de discriminar com bom grau de acerto que 90% das empresas insolventes foram classificadas corretamente.

Pesquisa realizada por Rebello (2010), desenvolvida no âmbito da Universidade Federal de Santa Catarina - UFSC, cujo título foi: “Os modelos de previsão de insolvência: uma análise comparativa de seus resultados”, baseou-se nos modelos brasileiros de Kanitz, Altman, Elizabetsky, Matias e Silva. No estudo, Rebello (2010) utilizou uma amostra de 12 empresas, sendo 6 em situação de concordata ou liquidação ocorrida no período de 1998 a 2001, foram consideradas insolventes, e no mesmo porte e segmento, outras 6 empresas não se encontravam em liquidação ou concordata para compor o grupo das solventes.

A conclusão obtida por Rebello (2010) é de que os modelos apontaram para classificações distintas, quando aplicados em uma mesma demonstração contábil. Por outro lado, o modelo de Silva, adaptado para indústrias para até um exercício, foi o que apresentou maior índice de acerto, obtendo 94% de sucesso no grupo de insolventes e de 100% no de solventes, já o modelo para até dois exercícios apresentou índices de 88% e 50% para empresas insolventes e solventes, respectivamente.

Outra pesquisa que cabe mencionar foi o estudo desenvolvido por Nascimento, Pereira e Hoeltgebaum (2010), os quais replicam os modelos desenvolvidos por Elizabetsky (1976), Matias (1976), Kanitz (1978), Silva (1982) e Altman et al. (1979) em grandes empresas aéreas brasileiras. No entanto, compusera a amostra apenas duas empresas, TAM Linhas Aéreas S/A e Gol Linhas Aéreas Inteligentes S/A. A opção por essa escolha foi devida à acessibilidade dos dados. Utilizaram como fonte de coleta dos dados o Balanço Patrimonial (BP) e a Demonstração do Resultado do Exercício (DRE), no período de 2004 e 2008.

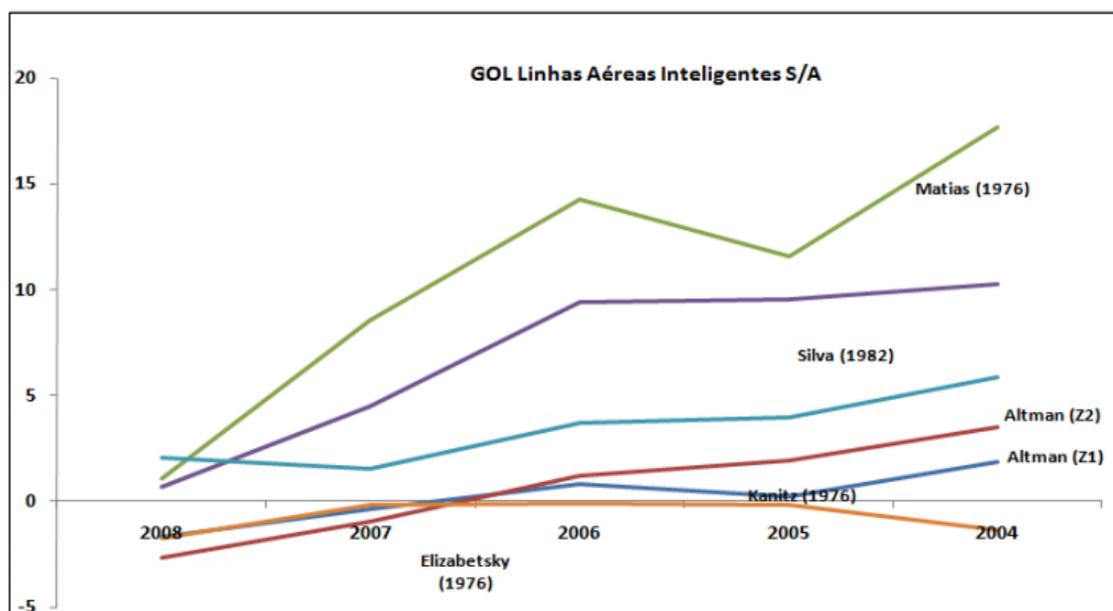
Os resultados obtidos por Nascimento et al. (2010) indicaram que, no caso específico da Gol Linhas Aéreas Inteligentes S/A, detectaram-se indícios de solvência para os cinco anos

analisados, de acordo com os modelos de Matias (1976), Kanitz (1978), e Silva (1982) e, nos modelos de Altman et al. (1979) e Elizabetsky (1976), apresentaram indícios de insolvência.

Os resultados de Nascimento et al. (2010), para a análise da Gol Linhas Aéreas Inteligentes S/A, estão alinhados com achados de Aranha e Lins Filho (2005) que afirmam que essa empresa apresentava trajetória de sucesso.

Por outro lado, no caso da companhia TAM Linhas Aéreas, S/A, Nascimento et al. (2010), verificaram que apenas dois dos modelos apresentaram situação de solvência, o de Matias (1976) e o de Silva (1982). Ressaltam ainda que o modelo de Elizabetsky (1976) detectou situação de insolvência para os cinco anos investigados. Quanto ao modelo de Kanitz (1978), foi o que apresentou a maior discrepância no período analisado, demonstrando oscilações entre a solvência e insolvência durante os cinco anos. Os resultados estão representados no Gráfico 01.

Gráfico 01: Aplicação dos Modelos de Insolvência na GOL Linhas Aéreas Inteligentes S/A

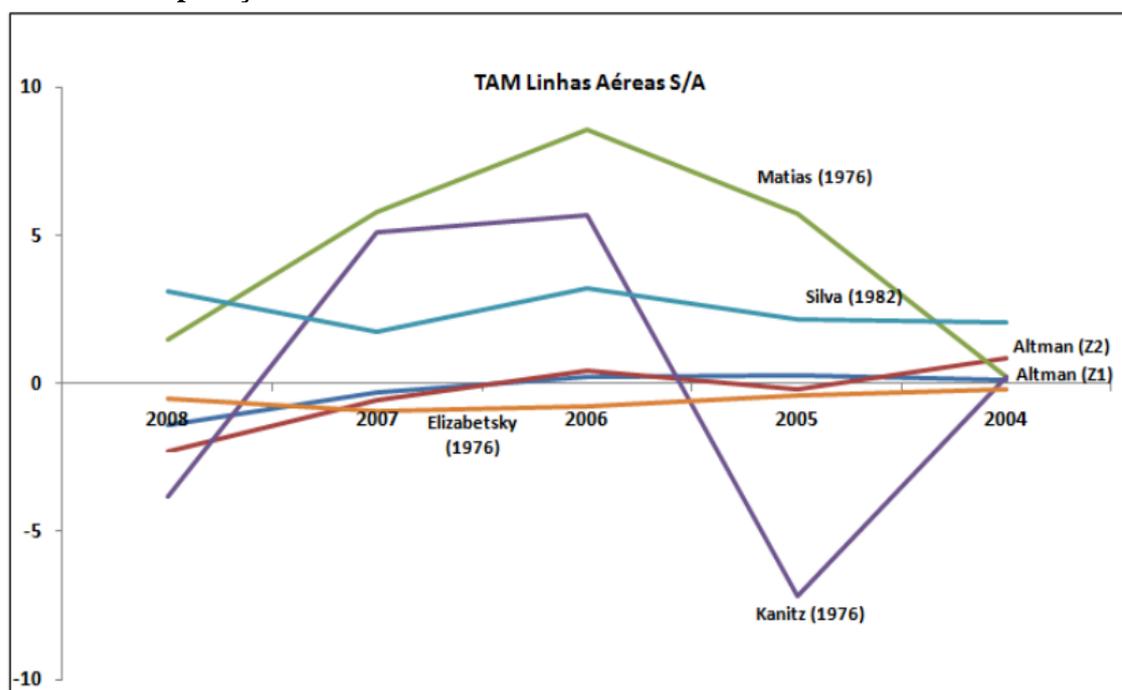


Fonte: Nascimento et al., 2010

No ponto de vista de Nascimento et al. (2010), os resultados corroboram com os achados de Aranha e Lins Filho (2005) que também identificaram a situação de insolvência na empresa no período de 2002 e 2003. Aranha e Lins Filho (2005) apresentaram estudo no qual aplicaram o Modelo de Kanitz na avaliação de empresas do setor de aviação comercial brasileiro. Os dados foram os das companhias GOL, TAM, VASP e VARIG, no período de 2002 a 2004. Para a Gol, os resultados apontaram situação de solvência, enquanto para as demais, os resultados foram para insolvência.

Portanto, Nascimento et al. (2010), ao replicarem os modelos de previsão de insolvência desenvolvidos pelos pesquisadores Elizabetsky (1976), Kanitz (1978), Matias (1976), Altman et al. (1979) e Silva (1982), para o período de 2004 a 2008, verificaram que, em linhas gerais, a GOL Linhas Aéreas Inteligentes S/A apresentou uma performance predominantemente favorável, enquanto a TAM Linhas Aéreas S/A demonstrou oscilações. Os resultados obtidos estão evidenciados no Gráfico 02.

Gráfico 02: Aplicação dos Modelos de Insolvência na TAM Linhas Aéreas S/A



Fonte: Nascimento et al., 2010

Por outro lado, com a finalidade de desenvolver um guia prático para construção de índices-padrão para o setor elétrico, Aranha (2015) cita os trabalhos mais renomados que desenvolveram modelos de previsão de insolvência e contribuíram para evolução de novas pesquisas na área de insolvência das empresas, em que:

O objetivo da Análise Discriminante é construir uma linha fronteira por meio de gráfico, de modo que, se a empresa estiver à esquerda da linha, provavelmente ela não se tornará insolvente, mas, poderá ir a falência se mudar para a direita da linha. A essa linha fronteira chama-se função discriminante. Assim, o uso da análise discriminante objetiva separar empresas solventes de empresas insolventes e, ao mesmo tempo, determina o peso relativo de cada índice, sem que prevaleçam critérios arbitrários na sua determinação.

Por outro lado, mas em sintonia com a pesquisa científica e com o propósito de desenvolver uma função discriminante na previsão de insolvência em empresas que compõe o setor de materiais de construção em Portugal, Girão (2015) obteve as seguintes amostras em

períodos distintos: empresas que entraram em insolvência em 2008, no entanto, a economia encontrava-se em crescimento, e companhias que entraram em insolvência em 2014, mas, a economia estava em recessão.

No estudo de Girão (2015), citaram-se vários estudos relacionados à análise discriminante e outros métodos estatísticos utilizados, por exemplo, Análise Univariada, Análise Discriminante Multivariada, Modelo Logit, Modelo Probit, Redes Neurais Artificiais, Método *Data Envelopment Analysis*. Não obstante, após análise criteriosa, optou-se em utilizar a Análise Multivariada Discriminante, a qual apresentou em estudos anteriores um grau de discriminação superior aos demais: 90% de acordo com o estudo de Pereira, Basto, Diaz Gómez e Albuquerque (2010) e 85% na pesquisa de Aziz e Dar (2006).

Girão (2015) também desenvolveu a função discriminante e, ao aplicar o modelo de 2014 à amostra de 2008, obteve uma taxa classificativa de 87,5% e, quando aplicado ao modelo de 2008 com a amostra de 2014, o percentual de classificação foi 82,5%.

Recentemente, outros pesquisadores vêm desenvolvendo pesquisa com o uso do método estatístico de Análise Discriminante. Stupp (2015), por exemplo, se fez valer do método estatístico de Análise Discriminante e Regressão Logística utilizando 29 indicadores econômico-financeiros e obtendo um resultado muito similar nos dois métodos aplicados, 76,1% e 76,2% respectivamente.

Em continuidade com a pesquisa, Stupp (2015) realizou um teste de comparabilidade da função previsão de insolvência antes adoção IFRS e após adoção IFRS. Sendo assim, a média antes adoção IFRS foi de 73,5% e 82,1% após adoção. Percebe-se que houve uma queda no poder discriminatório para o período antes adoção e uma melhora significativa para o período após adoção das normas internacionais de contabilidade.

Em outro estudo realizado por Marques e Milani (2017), com o objetivo de verificar se o retorno das empresas industriais é afetado pela variação da liquidez, esses índices foram analisados como variáveis independentes e os indicadores de rentabilidade como dependentes. Utilizou-se a análise da regressão linear para o estudo dos índices, sendo assim, detectaram que os resultados encontrados indicam que a análise da relação rentabilidade-liquidez é sensível em partes. Porém, diversos estudos empíricos apresentam evidências contrárias, encontrando um sinal positivo para essa relação.

Em estudo realizado por Andrade e Lucena (2018), utilizando a análise de desempenho dos modelos de previsão de insolvência e a implementação das normas internacionais de contabilidade, replicaram os modelos de Elizabetsky (1976); Kanitz (1978); Altman et al. (1979); Matias (1979); Silva (1982); Kasznar (1986); Sanvicente e Minardi (1998) e Scarpel (2000). Utilizaram uma amostra de 17 empresas insolventes no período de 2004 a 2015, no entanto, apenas os modelos de Elizabetsky (1976) e Sanvicente e Minardi (1998). Dessa forma, obtiveram melhor desempenho de predição de insolvência com 94%, seguido pelo modelo de Altman et al. (1979), com aproximadamente 76% de classificação correta.

Todos os modelos em análise foram submetidos a uma outra comparação após adoção das normas internacionais de contabilidade. O que se observa é que os modelos que obtiveram melhor desempenho na primeira análise se mantiveram, havendo ainda um aumento no percentual de predição de insolvência no modelo de Altman et al. (1979).

2.2 Estudos Anteriores Desenvolvidos no Exterior

Com o mesmo propósito, Silva (2016) evidencia em sua literatura a descrição histórica dos principais estudos e modelos desenvolvidos no exterior sobre previsão de insolvência. De acordo com o estudo de Fitz (1932) foram selecionadas, aleatoriamente, 19 empresas que haviam falido no período de 1920 a 1929, com o objetivo de compará-las com 19 outras empresas bem-sucedidas.

Esse estudo tinha como foco detectar se os índices das companhias bem-sucedidas eram satisfatórios, ou se os índices das empresas falidas eram desfavoráveis e se a maioria dos índices das companhias bem-sucedidas eram favoráveis ou desfavoráveis e, em que condições. Tendo comparado os índices dos dois grupos de empresas com um padrão mínimo estabelecido, Fitz observou que os índices das empresas bem-sucedidas os ultrapassam, na maioria dos casos, enquanto as empresas falidas estiveram abaixo daquele padrão mínimo fixado.

Entre um conjunto de índice examinados, os mais significativos foram patrimônio líquido sobre passivo e lucro líquido sobre patrimônio líquido.

No estudo realizado por Winakor e Smith, em 1935, apud Silva (2016) cuja amostra foi bem significativa comparada ao estudo de Fitz, selecionaram 183 empresas que faliram no período de 1923 a 1931. Analisaram os 10 anos que antecederam as respectivas falências, tendo sido examinados e computados 21 índices que foram montados com base na padronização dos demonstrativos financeiros.

Valeram-se dos índices médios da metade de todas as empresas com a finalidade de comparar as mudanças individuais em todo o grupo. Observou-se que, à medida que se aproximava o ano de falência, os índices iam se deteriorando. Para amostra de 183 empresas, o índice de capital de giro sobre o ativo total foi o melhor preditor.

Com a finalidade de aprimorar a pesquisa, Merwin, em 1942, segundo Silva (2016), delimitou seus estudos nas pequenas empresas com ativos totais abaixo de \$250.000, no período de 1926 a 1936. Após examinarem apenas três tipos de índices, concluíram que o capital de giro sobre o ativo total foi o melhor indicador de falência.

Em continuidade ao estudo de Merwin, utilizou-se de duas abordagens, sendo uma delas para determinar uma faixa de variação (máxima e mínima) para cada índice em todos os anos, baseando-se em empresas sobreviventes como parâmetro. Quanto à segunda abordagem utilizada, foi uma “média calculada”, também refletindo o sucesso das empresas sobreviventes (SILVA, 2016).

As empresas em extinção foram consideradas muito abaixo da “média calculada” e fora do limite da faixa de variação (máxima e mínima) estabelecida a partir das empresas sobreviventes. Esse comportamento foi detectado seis anos antes da interrupção das atividades das empresas em extinção (SILVA, 2016).

Similarmente aos trabalhos desenvolvidos um pouco antes, o pesquisador Tamari, a fim de melhorar os instrumentos de previsão de insolvência ou falência, atribuiu pesos aos índices utilizados nas análises das empresas. Ainda, segundo Silva (2016), Tamari é referenciado como o primeiro a usar uma espécie de “composto ponderado” de vários índices, com vistas a prever falência ou insolvência. Valeu-se de seis índices aos quais foram atribuídos pesos cuja soma foi 100.

Para cada índice, a empresa obtém certos valores que, multiplicados pelos seus respectivos pesos, obtém-se uma pontuação para integrar uma escala particular. O índice que recebeu maior peso foi o do lucro e capital social mais reservas sobre o passivo total, considerados como os melhores indicadores de falência. O teste do “índice–risco” de Tamari foi feito para empresas um ano antes da falência, comparados aos índices de todas as empresas industriais (norte-americanas) no período de 1956 a 1960 (SILVA, 2016).

Inegavelmente, a fim de analisar melhor outros índices financeiros, Beaver, em 1966, fez-se valer de um teste de classificação dicotômica. Utilizou-se como amostra dados sobre

falência, não pagamentos de dividendos e inadimplência com debenturistas de 79 empresas norte-americanas, no período de 1954 a 1964, e comparou-os com dados de 79 empresas com boa saúde financeira, dos mesmos ramos e volume de ativo. Os demonstrativos contábeis das empresas insolventes foram agrupados por ano, durante cinco anos antes da insolvência, para serem comparados com as do grupo de empresas solventes (SILVA, 2016).

Em seu estudo Beaver usou um teste de classificação dicotômica, cuja técnica se resume: “[...] as empresas são aleatoriamente divididas em duas subamostras. Para um dado índice, os dados da primeira amostra são dispostos em ordem crescente. A disposição é examinada para se encontrar um índice limite (crítico), ideal, um ponto crítico que minimize a percentagem de predições incorretas. Se o índice de uma empresa está abaixo do índice limite (crítico), ela é classificada como falida [...], (SILVA, 2016).

Ainda, segundo Silva (2016), para Beaver, o ponto crítico ideal para primeira subamostra foi usado para prever a situação de falência das empresas na segunda subamostra. De modo semelhante, um ponto crítico ideal foi derivado para a segunda subamostra e usado para prever a situação de falência das empresas na primeira subamostra. Completado esse processo, o resultado é a capacidade de predição dos índices. Com apenas dois índices – geração de caixa sobre exigível total e lucro líquido sobre ativo total, considerados de maior capacidade de predição, o erro de classificação da amostra de Beaver foi de 13% para um ano antes da falência.

Os estudos de Backer e Gosman, em 1978, segundo Silva (2016), realizaram pesquisa sobre o nível de liquidez de companhias norte-americanas, no período de 1947 a 1975 e constataram que houve uma queda nos índices das empresas. Dessa forma, consideraram que a pesquisa foi de grande valia e publicaram em seu livro *Financial Reporting and Business Liquidity*. Para que Backer e Gosman alcançassem um nível de profundidade da pesquisa com uma maior fidedignidade utilizaram dos procedimentos de questionários e entrevistas com perguntas bem diretas, como: o público deveria ser alertado das situações de insolvência? Qual a importância dos índices financeiros em suas avaliações”?

Para essa pesquisa, Backer e Gosman valeram-se de 33 índices financeiros, cujo critério de seleção foi que tivessem sido citados nas entrevistas; que fossem encontrados em pesquisas na literatura específica; que fossem relatados pelas agências de informações. Utilizaram, ainda, de alguns parâmetros para classificar as empresas em solventes ou insolventes com o apoio dos recursos estatísticos: teste T, análise fatorial e análise discriminante (SILVA, 2016).

Diferentemente de Altman e vários outros estudos realizados por outros pesquisadores, por exemplo Topa, em 1979, que seguiu uma linha com o conceito de probabilidade subjetiva, enquanto, através da análise discriminante, os pesos de cada fator podem ser atribuídos por processos objetivos, Topa classificou os fatores a serem analisados para fins de concessão de crédito em duas categorias (SILVA, 2016):

1 – Fatores determinantes: que por si só são capazes de definir a validade ou não do crédito:

- Caráter;
- Conceito de praça;
- Experiência anterior;
- Seguros.

No entanto, na visão de Topa, para que fosse possível prosseguir com a análise da solicitação de crédito, era necessário que não fosse rejeitado nenhum dos fatores determinantes contido no primeiro passo ou análise. Sendo assim, se aprovado em todos os itens, segue-se para o segundo passo, fatores complementares (SILVA, 2016).

2 – Fatores complementares: utilizados para determinar o risco do crédito em “aceitável” ou “não”, através de pesos atribuídos a estes.

Para seu modelo, Topa fez uso de critérios subjetivos, valendo-se, por exemplo, do Teorema de Bayes, também conhecido como regra das probabilidades das causas. Em seu modelo foi submetido a uma comprovação empírica, tendo sido constatada sua validade num teste com 55 empresas (SILVA, 2016).

Portanto, verifica-se que a busca por modelos que consigam predizer insolvência foi motivada por uma necessidade por parte dos usuários das informações de cunho econômico-financeiro das companhias, principalmente diante da grande crise motivada pela queda do mercado norte-americano de ações em 1929.

2.3 Análise Econômico-Financeira

A análise dos demonstrativos financeiros busca verificar se é possível a sobrevivência e desenvolvimento pretendido pela empresa. Essa conclusão virá da análise de indicadores fundamentalistas (endividamento, liquidez, rentabilidade e atividade), que possibilitarão encontrar características da empresa e também projetar situações que ela pode vivenciar mais em frente.

Ademais, Silva (2016) pontua em sua obra a importância da análise financeira para subsidiar decisões de investir e de emprestar, entre outras, pois ele menciona que a análise financeira foi, e continuará sendo utilizada por muito tempo para essas finalidades. É necessário, entretanto, que, em benefício da própria análise financeira, determinados instrumentos, como os índices financeiros, sejam questionados e submetidos a testes, a fim de que se conheça sua capacidade de nos permitir a fazer algumas previsões, o que, efetivamente, representa o teste crucial de qualquer teoria.

Além disso, é necessário que, em benefício da própria análise financeira, determinados instrumentos, como os índices financeiros, sejam questionados e submetidos a testes, a fim de que se conheça sua capacidade de nos permitir a fazer algumas previsões (SILVA, 2016).

Em se tratando da diferença entre situação econômica e situação financeira, a primeira leva em consideração o patrimônio da empresa e os lucros e prejuízos, já a segunda está mais ligada ao fluxo de caixa. Uma empresa pode ter um bom patrimônio e lucros (situação econômica boa) e ainda assim estar com dificuldade para pagar dívidas de curto prazo (situação financeira ruim); são análises que se complementam.

Ressalta-se que os índices apresentados isoladamente não nos dizem nada, portanto, para tirar uma conclusão da análise, são necessárias comparações. Essas comparações podem ser feitas com períodos passados da própria empresa (verificando a tendência do índice) e com empresas concorrentes, mantendo a uniformidade, a consistência e a relevância.

Por outro lado, a análise de índices também é conhecida por análise de indicadores ou por análise de quocientes (MATARAZZO, 2017). São nomes diferentes para a mesma técnica. A utilização de índices (quocientes) tem como principal objetivo permitir ao analista extrair tendências e comparar os índices com padrões preestabelecidos. Mais do que retratar o que aconteceu no passado, a finalidade da análise é fornecer algumas bases para inferir o que poderá acontecer no futuro.

As finanças de uma empresa podem afetar a estrutura da organização. Nesse sentido, a administração financeira deve ajudar a planejar e a nortear o futuro da empresa. E para que se possa acompanhar a evolução e identificar possíveis deficiências na gestão dos negócios, é de suma importância a análise das demonstrações financeiras através de índice de liquidez o qual a literatura evidencia em suas obras, sendo assim, utilizaremos, dentre essas, a de **Liquidez Corrente, Liquidez Seca e Liquidez Geral**.

2.3.1 Liquidez

A liquidez de uma empresa é medida em termos de sua capacidade de saldar suas obrigações e compromissos financeiros em curto e em longo prazo. A liquidez diz respeito à solvência da posição financeira geral da empresa, demonstrando certa facilidade em honrar suas obrigações em determinada data. Como um precursor comum de dificuldades financeiras, é uma liquidez baixa ou em declínio, esses índices podem fornecer sinais antecipados de problemas de fluxo de caixa e insolvência iminente do negócio, (ARANHA, 2015).

Como regra geral, a leitura dos índices de liquidez é feita da seguinte maneira: Índice de liquidez maior do que 1: a empresa possui alguma folga para cumprir com suas obrigações; já o índice de liquidez igual a 1: os valores à disposição da empresa empatam com as contas que ela tem para pagar e o índice de liquidez menor do que 1: se a empresa precisasse quitar todas as suas obrigações no curto prazo, ela não teria recursos suficientes.

Por conseguinte, quanto maior for o índice de liquidez da empresa, maior tende a ser sua saúde financeira. Não obstante, esses índices contábeis não devem ser considerados isoladamente. Para ter uma visão geral do grau de liquidez de uma companhia, é preciso também que se leve em consideração seu tipo de atividade e se resguarde de analisar outros indicadores para que se tenha uma avaliação mais robusta da real situação em que a empresa se encontra.

A análise de liquidez é obtida através de quocientes e relacionam os bens e os direitos da empresa por intermédio de uma operação de divisão, ou seja, mede o quanto a empresa tem para cada unidade monetária que ela deve, e os dados para essa análise também são extraídos do Balanço Patrimonial.

Nessa mesma sintonia de pensamento, Assaf Neto (2020), cita que a liquidez revela, mais especificamente, a habilidade de uma empresa gerar caixa de maneira a atender adequadamente a suas obrigações financeiras.

Tabela 08: Indicadores de Liquidez

Grupo de Índices	Índices
Indicadores de Liquidez	Liquidez Geral
	Liquidez Corrente
	Liquidez Seca

Fonte: o Autor, 2021

Índice de liquidez corrente, também chamado de índice de liquidez comum, mede a capacidade de pagamento de uma empresa em curto prazo. Ele é um dos indicadores mais conhecidos para se analisar a capacidade de pagamento de uma companhia.

O índice de liquidez corrente é calculado dividindo-se o ativo circulante da empresa (seus direitos de curto prazo, como o dinheiro em caixa, bancos, clientes e os estoques) pelo passivo circulante (as dívidas a curto prazo, como empréstimos, impostos e fornecedores). Na visão de Gitman, o fator do índice é relativamente aceitável de acordo com o segmento de atuação da empresa.

O índice de liquidez seca é similar ao índice de liquidez corrente. A única diferença é que ele exclui os estoques do ativo circulante da empresa, já que esses direitos são menos realizáveis a curto prazo. Considera, portanto, os valores de que a empresa dispõe para pagar suas contas em curto prazo ainda que não consiga vender nada do que tem estocado. Como é mais rigoroso no cálculo do ativo, o índice de liquidez seca é menor do que o de liquidez corrente.

O índice de liquidez geral busca dar uma visão da solvência de uma empresa a longo prazo. Por esse motivo, além dos itens considerados na liquidez corrente, o índice de liquidez geral adiciona os direitos e as obrigações da empresa para um prazo mais alargado, ou seja, seu Realizável a Longo Prazo e seu Exigível a Longo Prazo. Essas duas contas também podem ser obtidas no balanço patrimonial.

Sozinho, o índice de liquidez geral não possui tanta utilidade quanto os anteriores. Isso porque a empresa pode, por exemplo, ter feito um financiamento longo para investir em sua modernização, e os recursos para quitar essa dívida chegarão paulatinamente ao longo dos anos, não sendo necessários agora.

Dessa maneira, a análise de uma série histórica da liquidez geral poderá demonstrar se a companhia está ganhando ou perdendo capacidade de pagamento.

2.3.2 Indicadores de Estrutura de Capital ou Endividamento

Na visão de Lott (2020), o qual relata que a estrutura de capital é um dos tópicos mais relevantes em finanças corporativas, no entanto, vários autores renomados como Myers (1984), Myers e Majluf (1984), Titman e Wessels (1988), Rajan e Zingales (1995), Graham, Leary e Roberts (2015) e Ardalan (2017), não possuem uma opinião sobre qual é a melhor ou a mais adequada combinação de dívida para as companhias.

Sendo assim, optou-se em utilizar no estudo os três indicadores de estrutura de capital, conforme tabela 09, devido a sua relevância na composição da análise.

Tabela 09: Indicadores de Estrutura de Capital ou Endividamento

Grupo de Índices	Índices
Indicadores de Estrutura de Capital ou Endividamento	Imobilização do Capital Próprio (ICP)
	Participação de Capitais de Terceiros (PCT)
	Grau de Endividamento (GE)

Fonte: o Autor, 2021

2.3.3 Indicadores de Rentabilidade

De acordo com Aranha (2015), os indicadores de rentabilidade têm por objetivo avaliar o desempenho final da empresa; segundo ele a rentabilidade é o reflexo das políticas e das decisões adotadas pelos seus administradores, expressando objetivamente o nível de eficiência e ou o grau de êxito econômico-financeiro atingido.

Além disso, Assaf Neto (2020) afirma que a rentabilidade se comporta similarmente aos diversos tipos de negócios, diferenciando-se basicamente pela natureza dos fatores colocados à disposição. Por exemplo, numa instituição financeira, os recursos captados representam suas matérias-primas, que são negociadas principalmente sob a forma de créditos e empréstimos concedidos e investimentos.

No entanto, como todo negócio, independente do seu ramo de atuação, a empresa tem por objetivo maximizar a riqueza de seus proprietários pelo estabelecimento de uma adequada relação risco-retorno prezando sempre por uma rentabilidade satisfatória aos seus investidores.

De acordo com a literatura de Assaf Neto (2020), o retorno sobre o patrimônio líquido fornece o ganho percentual auferido pelos proprietários como uma consequência da margem de lucro, da eficiência operacional, do planejamento eficiente de seus negócios.

Já o retorno sobre o investimento total demonstra os resultados das oportunidades de negócios acionadas pelas empresas. É uma medida de eficiência influenciada principalmente pela qualidade do gerenciamento da lucratividade dos ativos e juros passivos.

Segue relação dos principais indicadores de rentabilidade:

Tabela 10: Indicadores de Rentabilidade

Grupo de Índices	Índices
Indicadores de Rentabilidade	<i>Return on Invested Capital (ROIC)</i>
	<i>Return on Equity (ROE)</i>
	<i>Return on Assets (ROA)</i>
	Margem Ebit
	Margem Ebitda
	Margem Bruta (MB)
	Margem Líquida (ML)
	Giro do Ativo (GA)
	Giro do Patrimônio Líquido (GPL)

Fonte: o Autor, 2021

2.4 Análise Discriminante

O pioneiro no estudo da análise discriminante foi Fischer que a propôs na primeira metade do século XX, como um critério mais confiável para a classificação de novas espécies de vegetais, sendo rapidamente adotada além da Taxonomia e Sistemática Vegetal (MAROCO, 2003).

Atualmente, percebe-se uma grande aplicação dessa técnica estatística de análise em diversos campos do conhecimento, como biologia, antropologia, marketing, comportamento do consumidor, entre outros (FÁVERO et al., 2009).

No estudo de finanças, destaca-se o trabalho de Edward Altman que, em 1968, publicou no *The Journal of Finance* o artigo intitulado *Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy*, bem como cita ainda outros autores que também contribuíram significativamente para a aplicação da análise discriminante (FÁVERO et al., 2009).

Durante muitos anos, a análise discriminante tem recebido uma grande atenção teórica de diversas áreas, como marketing, em que podem ser citados os trabalhos de Frank, Massy e Morrison (1965), Morrison (1969), Crask e Perreault (1977) e Hora e Wilcox (1982). Merece destaque também a expressiva contribuição de alguns trabalhos em relação à modelagem matemática da análise discriminante, como os de Lachenbruch e Mickey (1968), Marks e Dunn (1974), McLachlan (1974), Krzanowski (1975), Randles, Broffitt, Ramberg e Hogg (1978), Constanza e Afifi (1979) e Fraley e Raftery (2002) (FÁVERO et al., 2009).

Nos Estados Unidos e na Europa, há, atualmente, uma vasta aplicabilidade da análise discriminante nas ciências sociais e do comportamento e, no Brasil, o avanço do conhecimento

permite a aplicação da análise discriminante em diversas áreas como ciências sociais aplicadas (finanças), biologia (zoologia, zootecnia, medicina veterinária), biologia humana; sendo assim, nota-se que o uso desse tipo de análise está mais presente em diversas áreas, devido à contribuição direta dos principais *softwares* estatísticos que apresentam essa técnica (FÁVERO et al., 2009).

Portanto, desde o trabalho de Altman (1968), a análise discriminante tem sido a técnica estatística utilizada para classificar uma observação em um dos vários agrupamentos, *a priori*, dependente das características individuais da observação. É utilizada principalmente para classificar e/ou fazer previsões em problemas nos quais as variáveis dependentes aparecem em forma qualitativa, por exemplo, do sexo masculino ou do sexo feminino, falência ou não à falência. Portanto, o primeiro passo é estabelecer classificações de grupos explícitos.

Sendo assim, Altman (1968, p. 591), “após cuidadosa consideração da natureza do problema e do objeto do trabalho, uma análise discriminante múltipla (*MDA*) foi escolhida como técnica estatística adequada”.

De certo modo, Altman (1968), foi bem criterioso quanto a sua escolha de utilizar a análise discriminante multivariada, pois já vinha acompanhando os trabalhos desenvolvidos um pouco antes e observou os pontos falhos e os métodos estatístico empregado na pesquisa.

Do mesmo modo, Sicsú (1975, p. 1) expõe que a análise discriminante é “um conjunto de processos estatísticos com a finalidade de localizar um indivíduo *E* em uma de *K* populações distintas, previamente conhecidas, admitindo-se que *E* realmente pertence a uma dessas *K* populações”.

Para Matarazzo (2017), a função discriminante é a “discriminação” entre dois ou mais grupos definidos “*a priori*” estabelecendo-se os pesos de cada variável que maximize a variância entre os grupos e minimize a variância dentro de cada grupo de variáveis independentes.

Assim também, Ragsdale (1995, p. 379) define análise discriminante como “uma técnica estatística que usa informações disponíveis de um conjunto de variáveis independentes para prever o valor de uma variável dependente discreta ou categórica”.

A análise discriminante é uma técnica bem difundida pelos autores desde as primeiras pesquisas feitas com a utilização dessa função. Pueri (2002, p. 43) assim descreve a análise discriminante “em essência, procura desenvolver uma regra matemática (função) que sirva

como ferramenta de classificação de uma nova observação em algum dos grupos previamente estabelecidos. Para tanto, são verificados os valores assumidos pelas variáveis independentes”.

Na pesquisa de Castro Junior (2003, p. 2), ele afirma que “os primeiros estudos usaram a técnica da análise discriminante linear (ADL): primeiramente a análise discriminante univariada com o estudo de Beaver (1966) e, posteriormente, a análise discriminante multivariada com Altman (1968)”.

Sobre a análise discriminante, Silva (2016, p. 302), comenta que:

[...] é uma ferramenta estatística utilizada para classificar determinado elemento E em determinado grupo entre os grupos existentes. Para isso, é necessário que o elemento E a ser classificado pertença realmente a um dos i grupos, e que sejam conhecidas as características dos elementos dos dois grupos, de modo a permitir a comparação entre as características do elemento que desejamos classificar com as características dos elementos dos diversos grupos. Essas características são específicas a partir de um conjunto de n variáveis aleatórias.

Uma das vantagens do uso da análise discriminante para Silva (2016) é que os pesos a serem atribuídos aos índices são determinados por cálculos e processos estatísticos, o que exclui a subjetividade ou mesmo o estado de espírito do analista no momento da análise.

Para as situações de discriminação entre duas populações normais de mesma matriz de covariância, Silva (2016, p. 305), apud Fisher (1936) descreve que “a função discriminante de Fisher apresenta propriedades ótimas” e destaca ainda que o artigo “é o suficiente para fornecer uma ideia genética do que seja esse valioso instrumento estatístico. Cabe frisar que, após Fisher, a análise discriminante evoluiu com a contribuição de outros estudiosos”.

Segundo Corrar, Paulo e Dias Filho (2007, p. 236), “a análise discriminante objetiva encontrar uma função matemática para discriminar ou segregar elementos entre grupos preestabelecidos e assim apresentar uma divisão dos resultados conforme a sua classificação”. Mingoti (2013, p.213) comenta que é uma técnica que pode ser utilizada para organizar a classificação de elementos de uma amostra ou população, em que os grupos são conhecidos a *priori*.

A análise discriminante ou função discriminante é uma técnica de dependência multivariada utilizada quando se tem variáveis não-métricas. Hair et al. (2009) tratam da situação de uma variável dependente e se tem o interesse em apresentar uma forma de previsão de solvência ou insolvência, se é um bom pagador ou não, se a empresa terá lucro ou não.

A técnica procura, basicamente, responder se um elemento pertence ou não a uma determinada categoria. Tratando-se da análise de risco de crédito, a análise discriminante, ou especificamente a função discriminante, indicará se uma empresa pertence a um grupo de firmas solventes ou ao conjunto das insolventes (HAIR et al., 2009).

A variável dependente ou variável estatística é o constructo resultante da combinação linear de uma ou mais variáveis independentes. No caso da existência de somente uma variável independente, temos a análise univariada e, quando existe um número maior de variáveis independentes, temos a análise discriminante multivariada. O valor previsto da função da discriminante é o escore discriminante, o qual é calculado para cada objeto (pessoa, empresa ou produto) na análise (HAIR et al., 2009).

A fórmula para representar essa metodologia é expressa da seguinte forma:

$$Z_{jk} = a + W_1X_{1k} + W_2X_{2k} + \dots + W_nX_{nk}$$

Em que:

Z_{jk} = escore “Z” discriminante da função discriminante “j” para o objeto “k”.

a = é o intercepto.

W_i = peso discriminante para a variável independente i .

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

Sendo assim, a finalidade da análise discriminante é verificar se determinada empresa se classifica no grupo de empresas solventes ou insolventes, conforme a pontuação recebida, após apuração dos indicadores financeiros obtidos por meio de uma equação linear ou função discriminante, utilizando os dados das demonstrações contábeis das empresas.

Nesse contexto, os objetivos da análise discriminante são:

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

As variáveis independentes relevantes, formadoras da função discriminante, são obtidas por recurso à estatística Lambda (λ) de Wilks (HAIR et al., 2009).

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

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

Sendo:

- a) $SQE = \sum (y_i - \underline{y}_i)^2$ = soma dos quadrados dos erros dentro dos grupos;
- b) $SQT = \sum (y_i - \hat{y}_i)^2$ = soma dos quadrados totais;
- c) y = variável sob estudo;
- d) \underline{y}_i = valor médio de y ;
- e) \hat{y}_i = valor estimado de y .

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

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

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

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

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

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

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

onde:

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

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

2.4.1 Suposições da Análise Discriminante

Para aplicação da análise discriminante, são requeridos certos pressupostos. Para Hair et al. (2005), os pressupostos ou suposições mais importantes são a de normalidade das variáveis independentes e igualdade nas matrizes de dispersão e covariância dos grupos. A falta de normalidade pode causar problemas na estimação da função discriminante e matrizes de covariâncias desiguais podem afetar negativamente o processo de classificação.

Assim também, Corrar et al. (2014) descreveram pressupostos semelhantes para análise multivariada, dentre eles temos o de normalidade das variáveis independentes “os dados devem ter uma distribuição que seja correspondente a uma distribuição normal, esta é a suposição mais comum na análise multivariada, a qual se refere à forma da distribuição de dados para uma variável quantitativa individual e sua correspondência com a distribuição normal”, pois isso seria um padrão a ser observado nos métodos estatísticos.

Uma outra característica dos dados que pode comprometer os resultados é a multicolinearidade entre variáveis independentes. Essa característica indica se duas ou mais variáveis são correlacionadas, de maneira que uma variável pode ser explicada por outra, acrescentando pouco ao poder elucidativo do conjunto como um todo (HAIR et al. 2005).

O pressuposto de linearidade das relações entre as variáveis está implícito na função discriminante, pois relações não lineares não são refletidas na função, a menos que transformações específicas de variáveis sejam executadas para representar efeitos não lineares (HAIR et al. 2005).

Em mesma sintonia, Corrar et al. (2014) destacam que a linearidade pode ser utilizada como conceito de um determinado modelo em que terá as propriedades de aditividade e homogeneidade, no entanto, os modelos lineares preveem valores que são evidenciados em uma linha reta. De modo contrário, “a linearidade é uma suposição implícita nas técnicas multivariadas baseadas em medidas correlacionais de associação, incluindo regressão múltipla, regressão logística e análise fatorial”.

2.5 INSOLVÊNCIA

A insolvência possui vários conceitos, podendo ser econômica, empresarial, legal, casual, culposa, fraudulenta, entre outras. Para tanto, evidenciar-se-ão alguns estudos realizados e uma breve retrospectiva das leis de falência ou insolvência.

Figueiredo (2018), em uma análise crítica, faz menção das diferenças existentes entre Insolvência e falência, pois os conceitos são diferentes, sendo assim, serão abordadas estas designações: “a insolvência não se confunde com falência, ou seja, a impossibilidade de cumprir obrigações vencidas (insolvência) não implica a inviabilidade econômica da empresa ou a irrecuperabilidade financeira (falência)”. Dessa forma, falência significa “fingir, induzir em erro, ou falsidade nas promessas, sendo utilizado para situações de violação de confiança do devedor para com os seus credores quando não cumpriam com os seus compromissos”.

Em continuidade à pesquisa realizada por Figueiredo (2018), a empresa poderá se encontrar numa situação de insolvência quando o seu ativo for insuficiente para satisfazer o passivo exigível e, assim, não será possível cumprir com as obrigações financeiras que detém, devido à falta de liquidez e acesso ao crédito, ou seja, a empresa encontra-se em dificuldades financeiras e é impossibilitada de cumprir as suas obrigações.

Portanto, observa-se então que, nos casos de insolvência, as companhias não conseguem cumprir com as suas obrigações, por falta de liquidez, pois isso ocorre quando o passivo está suplantando o ativo. Assim sendo, numa sociedade em que o recurso ao crédito é uma realidade, a insolvência terá sempre de ser considerada para o assunto, isso porque a falta de liquidez impede o recurso ao crédito.

2.5.1 Evolução Histórica da Lei de Falência ou Insolvência

Desde os primeiros estudos científicos sobre a previsão de falência ou insolvência de empresas realizados por Fitzpatrick (1932), inegavelmente muito se avançou em estudos dessa

natureza, pois, cerca de 3 décadas após os estudos deste, surgiram, mesmo com algumas mudanças na lei de falência posteriormente, ferramentas estatísticas as quais passaram a fazer parte dos estudos de previsão de insolvência de empresas.

Há relatos que, em 1888, surgiu o primeiro Código Comercial, que era exclusivamente dedicado às Falências. Segundo Correia (1977), onze anos mais tarde, tem-se a publicação do Código das Falências o qual foi incorporado, em 1905, ao Código do Processo Comercial. Não obstante, surgiram algumas mudanças, ajustes e publicações de novos dispositivos de lei e, em 1935, surge o Código das Falências autônomo. Por não atender às necessidades dos usuários, esse código, quatro anos mais tarde, perde sua autonomia para ser incorporado a outro Código – o Código do processo Civil.

Tabela 11: Histórico do Código das Falências ou Insolvências

Ano	Lei	Definição
1888	Código Comercial	Surgimento do primeiro Código Comercial.
1899	Código das Falências	Publicação do Código das Falências.
1905	Código do Processo Comercial	Incorporação do Código das Falências no Código do Processo Comercial.
1935	Código das Falências Autônomo	Publicação do novo Código das Falências Autônomo.
1939	Código do Processo Civil	Incorporação do Código das Falências Autônomo ao Código do Processo Civil.
1961	Código do Processo Civil (alterações)	Revisão e alteração do Código Civil, pois, através deste, deram primazia aos meios preventivos do processo de falência, principalmente em relação à concordata ou acordo de credores, em lugar da liquidação.
1976	Código do Processo Civil (alterações / inclusões)	Alteração e inclusão de novos dispositivos de lei, introdução no léxico jurídico português das palavras “insolvência” e “insolvente”.
1986	Código do Processo Civil (proteção aos credores)	Novas Alterações: proteção aos credores, passando estes, em primeira instância, a decidir sobre o futuro da empresa.
1993	Código Autônomo	Surgimento do novo Código dos Processos Especiais de Recuperação da Empresa e de Falência.
1998	Código Autônomo	Instituição do Procedimento Extrajudicial de Conciliação de empresa.
2004	Código da Insolvência e Recuperação de Empresas	Publicação de um novo Código, revogando o anterior.
2005	Lei 11.101/05	Novos dispositivos para a Insolvência.
2012	Lei 11.101/05	Inclusão de novos dispositivos, pois o objetivo era permitir um acordo parcial de credores de forma a viabilizar a companhia quando em dificuldade financeira.

Fonte: o autor, 2021

Vale ressaltar que, mesmo com todas essas mudanças e revisões, a lei procurava sempre resguardar os direitos e os deveres dos envolvidos, como, dívidas dos empresários, ou mercadores, que se limitavam ao patrimônio do devedor.

Com a finalidade de elucidar o tema de previsão de insolvência ou falência, Castro Junior (2003) afirma em sua pesquisa que, apesar de não ter na época uma teoria definida sobre falência ou insolvência de empresas, diversos estudos empíricos com empresas de vários países do mundo têm sido realizados sempre com o intuito de buscar conhecer antecipadamente quais os determinantes de uma empresa em vias de entrar em processo de insolvência, ou mesmo, simplesmente se determinada empresa corre ou não o risco de entrar em um processo de descontinuidade.

No Brasil, após inúmeras alterações e revogações das leis conforme elucidado na tabela 11, temos a publicação da Lei 11.101/05. Esse dispositivo trouxe significativas alterações com o intuito de evitar a falência das companhias em crise. Uma delas foi a revogação das concordatas preventivas e suspensivas e, nessa lacuna, entra um único processo de recuperação que poderá ser judicial ou extrajudicial. O conceito e a finalidade da recuperação judicial estão dispostos no art. 47 da Lei 11.101/05.

No estudo realizado por Lott (2019), estão evidenciados os procedimentos jurídicos adotados no Brasil quando as companhias estão em situação de insolvência: “Recuperação, processo pelo qual empresas viáveis têm condições de adotar medidas que permitam a superação da crise financeira, garantido sua continuidade, por meio da proposição e da execução de um plano de recuperação”. Outro procedimento seria a falência (liquidação), “decretada quando a empresa se tornou inviável economicamente, consistindo, portanto, na liquidação dos ativos da devedora e repartição do resultado entre os credores”.

3. PROCEDIMENTOS METODOLÓGICOS

O presente trabalho tem como objetivo construir uma função discriminante para previsão de insolvência em empresas. Para esse fim, foram selecionadas companhias em situação de falência, em recuperação judicial, que apresentam sistematicamente prejuízos e que possuem passivo a descoberto. Essas companhias constituem o grupo de empresas insolventes e outro grupo de empresas solventes. Dos grupos de empresas foram coletados indicadores econômico-financeiros que serão utilizados na construção da função discriminante.

Nesse sentido, quanto aos objetivos do estudo, estes se enquadram como pesquisa descritiva. Richardson (2012) denomina a referida pesquisa descritiva como aquela que busca explicar a maneira pela qual um determinado fenômeno se comporta, quais fatores influenciam nas variáveis da pesquisa e se essas mudanças podem impactar de qual maneira a variável dependente, tendo em vista as causas e as consequências do fenômeno.

A presente investigação, quanto à natureza, classifica-se como aplicada porque gera produtos ou processos imediatos; possui caráter descritivo, quanto aos objetivos, uma vez que descreve os fatos observados sem interferir neles; quantitativa, com relação a sua abordagem, já que requer o uso de recursos e técnicas de estatística.

Dando ênfase à abordagem, Creswell (2014) pontua que se trata do manuseio ou tratamento de uma amostra em que se utilizam ferramentas estatísticas a fim de mensurar os dados coletados. E na mesma sintonia, (Gil, 2017) descreve que uma investigação possui caráter descritivo, quantitativo, quando utiliza de meio de análise de dados primários/secundários e, quanto aos procedimentos, é bibliográfica e documental, pois coloca o pesquisador em contato com publicações existentes sobre o tema e utiliza a análise de dados primários obtidos junto à Economática®.

Em conformidade com coleta de dados, Marconi e Lakatos (2017) afirmam que a pesquisa documental nada mais é do que a coleta de dados por meio de documentos. Estes podem ser escritos ou não, sendo por meio também de documentos eletrônicos disponíveis, através dos quais o autor pode fazer a coleta de dados em momento anterior ou posterior ao ocorrido.

Com relação à amostra utilizada neste trabalho, é composta de informações econômico-financeiras de empresas solventes e insolventes listadas na Bolsa, Brasil, Balcão – B3 de diversos setores e segmentos dos quais foram obtidos os indicadores contábeis que constituem as variáveis utilizadas.

Para coleta dos dados, ou seja, os indicadores econômico-financeiros, foi utilizado o banco de dados da Economática® do ano de 2019. Para efeito de classificação das companhias insolventes, foram consideradas aquelas em recuperação judicial, conforme listagem disponível na Comissão de Valores Mobiliários – CVM, as que apresentam prejuízos de forma sistemática e com Passivo a Descoberto.

Dentro desse contexto, para efeito de comparabilidade, as companhias selecionadas, solventes e insolventes, são dos mesmos segmentos no âmbito da B3.

Dentre as empresas insolventes ou que apresentam anomalias como prejuízos e Passivo a Descoberto, foram encontradas 53 companhias, no entanto, foi necessário excluir aquelas do setor financeiro devido a suas peculiaridades em relação as de serviços, comércio e indústria, bem como aquelas que, apesar de ativas na B3, não dispunham de dados econômico-financeiros. Dessa forma, restou uma amostra de 30 empresas em recuperação judicial, com prejuízos sistemáticos e com Passivo a Descoberto, conforme apresentado na tabela 12.

Da mesma forma, para efeito de homogeneidade e comparabilidade dos indicadores econômico-financeiros, foram selecionadas outras 30 empresas solventes dentre um rol de 353 companhias ativas na B3, dos mesmos segmentos das insolventes. Além do critério mencionado, foi levada em consideração a comparação do valor do Ativo Total, de forma a selecionar aquelas com volume de Ativo semelhante, a fim de obter grupos homogêneos em termos de segmentos e de volume de Ativo, também elencadas na tabela 12.

Nesse sentido, obtiveram-se dois grupos com 30 empresas cada, sendo o das companhias insolventes, que corresponde ao agrupamento “0” e o das solventes, o agrupamento “1”. As empresas que compõem as amostras estão descritas na Tabela 12.

Tabela 12: Relação de Empresas Solventes, em Recuperação Judicial, com Prejuízos Sistemáticos e com Passivo a Descoberto em 2019

Empresa Solventes – Agrupamento “1”	Empresa Insolventes – Agrupamento “0”	Subsetor Bovespa
Boa Safra	Pomi Frutas	Agropecuária
Casan	Orizon	Água e saneamento
Brf	Minerva	Alimentos processados
Marfrig	Minupar	Alimentos processados
Metal Leve	Plascar Part	Automóveis e motocicletas
Magazine Luiza	Lojas Arapua	Comércio
Carrefour	Bombril	Comércio e distribuição
MRV	PDG Realt	Construção civil
Tenda	Rossi Resid	Construção civil
Trisul	Viver	Construção civil
Sondotecnica	Eternit	Construção e engenharia
Portobello	Haga	Construção e engenharia
Ceee-Gt	Ceee-D	Energia elétrica
Cosern	Celgpar	Energia elétrica
Aersis	Bardella	Máquinas e equipamentos
Pratica	Nordon Met	Máquinas e equipamentos
Marcopolo	Recrusul	Material de Transporte
Randon Part	Riosulense	Material de Transporte
Tupy	Wetzel	Material de Transporte
Oceanpact	OSX Brasil	Petróleo e gás

Petrobras	Dommo	Petróleo e gás
Petrobras BR	Pet Manguinho	Petróleo e gás
Meliuz	Westwing	Programas e serviços
Nutriplant	Fer Heringer	Químicos
Tekno	Mangels Indl	Siderurgia e metalurgia
Dohler	Karsten	Tecidos vestuários
Pettenati	Tecelagem São José	Tecidos vestuários
Santanense	Teka	Tecidos vestuários
Cia Henring	Tex Renaux	Tecidos vestuários
Whirlpool	Hercules	Utilidade Doméstica

Fonte: o Autor, 2021

Para uma melhor didática na identificação das variáveis independentes, atribuíram-se nomenclaturas para cada indicador utilizado, abaixo listadas. Portanto, com base no banco de dados da Economática[®], inicialmente foram selecionados os seguintes indicadores com suas correspondentes nomenclaturas:

Tabela 13: Nomenclaturas das Variáveis Independentes

Grupos de Índices	Índices	Legenda
Indicadores de Liquidez	Liquidez Geral	X ₁
	Liquidez Corrente	X ₂
	Liquidez Seca	X ₃
Indicadores de Rentabilidade	Return on Invested Capital (ROIC)	X ₄
	Return on Equity (ROE)	X ₅
	Return on Assets (ROA)	X ₆
	Margem Ebit	X ₇
	Margem Ebitda	X ₈
	Margem Bruta (MB)	X ₉
	Margem Líquida (ML)	X ₁₀
	Giro do Ativo (GA)	X ₁₂
Giro do Patrimônio Líquido (GPL)	X ₁₃	
Capital de Giro	Capital de Giro	X ₁₁
Indicadores de Estrutura de Capital ou Endividamento	Imobilização do Capital Próprio (ICP)	X ₁₄
	Participação de Capitais de Terceiros (PCT)	X ₁₅
	Grau de Endividamento (GE)	X ₁₆

Fonte: o Autor, 2021

A partir dos indicadores, foi construído o modelo de insolvência, utilizando-se o modelo estatístico de análise discriminante de Fischer, para isso, utilizou-se o *software IBM SPSS Statistics*. Após construído, o modelo foi submetido a teste para sua validação.

As figuras que seguem (02 a 10) e tabela 14 são os resultados das saídas do *SPSS Statistic* para os dados do primeiro teste com todas as variáveis independentes selecionadas e os agrupamentos.

Casos não ponderados		N	Porcentagem
Válido		60	
Excluídos	Códigos de grupo omissos ou fora do intervalo	0	,0
	Pelo menos uma variável discriminante omissa	0	,0
	Códigos de grupo omissos ou fora do intervalo e pelo menos uma variável discriminadora omissa	0	,0
	Total	0	,0
Total		60	100,0

Figura 02: Resumo de Processamento
Fonte: Resultado da Pesquisa, 2021

Conforme se observa na figura 02, no processamento dos dados das 60 companhias que compõem a amostra, houve o processamento de 100% da amostra, demonstrando, desse modo, nenhuma rejeição dos dados.

O resultado de “saída”, conforme Tabela 14, são as médias e o desvio-padrão dos grupos. Observa-se que as variáveis X₄, X₅ e X₁₆ da amostra das insolventes “0” são as com maiores médias e desvios, enquanto que no grupo de solventes “1”, são as variáveis X₇, X₈ e X₁₀. Essa estatística descritiva tem o propósito de verificar qual ou quais variáveis pode ser mais significativa no modelo, ou seja, as que apresentam maior variabilidade.

Tabela 14: Médias e Desvio-padrão das Variáveis Independentes

Empresas	Variáveis	Média	Erro Desvio	N válido (de lista)	
				Não ponderado	Ponderado
0 = Insolventes	X ₁	,2749080984511	,2410089862844	30	30,000
	X ₂	2,0006151802951	8,0840515967261	30	30,000
	X ₃	1,8743360225509	8,0990064087075	30	30,000
	X ₄	426,54287280429	2119,85209924594	30	30,000
	X ₅	508,95719717333	3087,580656728013	30	30,000
	X ₆	-455,34485893096	2347,344105448565	30	30,000
	X ₇	-9223,3720368547	9223,372036854777	30	30,000
	X ₈	-9223,3720368547	9223,372036854777	30	30,000
	X ₉	41,209968451063	53,2855818242611	30	30,000
	X ₁₀	-9223,3720368547	9223,372036854777	30	30,000
	X ₁₁	-9223,3720368547	9223,372036854777	30	30,000
	X ₁₂	,518993909435	,8456048013983	30	30,000
	X ₁₃	-7,703404399883	30,4086720537714	30	30,000
	X ₁₄	-183,051255307452	827,872949654277	30	30,000
	X ₁₅	-1034,53827059199	3087,19626968093	30	30,000
	X ₁₆	5355,022147157933	9223,37203685477	30	30,000
1 = Solventes	X ₁	1,220508974098	,741684746671277	30	30,000
	X ₂	1,99781000183033	1,348817428844765	30	30,000
	X ₃	1,56099462297833	1,128420404551873	30	30,000
	X ₄	9,61851443920866	7,28972882572781	30	30,000

1 = Solventes	X ₅	27,92992306054	48,80565549411369	30	30,000	
	X ₆	9,65164766408666	12,3721863020708	30	30,000	
	X ₇	1150,90646267147	6211,22402430005	30	30,000	
	X ₈	1173,17911265870	6312,232489211684	30	30,000	
	X ₉	25,7035740835933	18,1938136792923	30	30,000	
	X ₁₀	1129,22610240632	6101,056278788099	30	30,000	
	X ₁₁	-9223,37203685477	24062114,56679106	30	30,000	
	X ₁₂	,844070798289459	,720801618339184	30	30,000	
	X ₁₃	2,834600675138436	3,471115660417372	30	30,000	
	X ₁₄	70,77238969832473	97,50577277808158	30	30,000	
	X ₁₅	281,6002432813	654,383210273904	30	30,000	
	X ₁₆	55,29823937613334	20,8516609907395	30	30,000	
	Total	X ₁	,747708536274586	,725441788164304	60	60,000
		X ₂	1,999212591062745	5,74598589379100	60	60,000
		X ₃	1,717665322764646	5,73514681088731	60	60,000
		X ₄	218,080693621751	1501,00725859456	60	60,000
X ₅		268,443560116936	2178,48245029001	60	60,000	
X ₆		-222,846605633441	1662,33688613933	60	60,000	
X ₇		-8754,518262381416	9223,3720368547	60	60,000	
X ₈		-8706,838690854802	9223,3720368547	60	60,000	
X ₉		33,4567712673283	40,2423586817677	60	60,000	
X ₁₀		-9223,37203685477	9223,3720368547	60	60,000	
X ₁₁		-9223,37203685477	16985902,3577448	60	60,000	
X ₁₂		,681532353862526	,796055912101398	60	60,000	
X ₁₃		-2,4344018623727	22,1057116188886	60	60,000	
X ₁₄		-56,1394328045639	598,2735831837474	60	60,000	
X ₁₅		-376,46901365534	2309,86923257682	60	60,000	
X ₁₆		2705,16019326703	9223,3720368547	60	60,000	

Fonte: Resultado da Pesquisa, 2021

A saída seguinte do *software IBM SPSS Statistics* é o Teste de Igualdade de Média de Grupos, conforme figura 03.

	Lambda de Wilks	Z	df1	df2	Sig
X1	,568	44,107	1	58	<,001
X2	1,000	,000	1	58	,999
X3	,999	,044	1	58	,834
X4	,980	1,160	1	58	,286
X5	,988	,728	1	58	,397
X6	,980	1,177	1	58	,282
X7	,954	2,770	1	58	,101
X8	,955	2,763	1	58	,102
X9	,962	2,275	1	58	,137
X10	,960	2,409	1	58	,126
X11	,991	,512	1	58	,477
X12	,958	2,568	1	58	,114
X13	,942	3,556	1	58	,064
X14	,954	2,781	1	58	,101
X15	,917	5,218	1	58	,026
X16	,977	1,371	1	58	,246

Figura 03: Teste de Igualdade de Médias de Grupos

Fonte: Resultado da Pesquisa, 2021

O teste de igualdade de médias do grupo demonstra quais variáveis possuem melhor discriminação, segundo Lambda de Wilks, o qual afirma que quanto menor a indicação da variável, melhor o poder discriminatório. Da mesma forma, o p-valor menor que 0,05 confirma essa premissa (Corrar et al. 2014). As variáveis com menores variáveis, conforme Lambda de Wilks, são X_1 , X_7 , X_8 , X_{12} , X_{13} , X_{14} e X_{15} .

Apenas a variável X_1 apresenta p-valor menor que 0,05.

Para identificar casos de multicolinearidade, são geradas pelo *SPSS Estatistics* as matrizes de covariância e correlação, a primeira serve de base para obtenção da matriz de correlação. A verificação da matriz de correlação possibilita ao pesquisador identificar prováveis casos de multicolinearidade e, dessa forma, identificar as variáveis que podem afetar o processo estatístico (CORRAR et al. 2014). Cabe ressaltar que, para Gujarati (2011), a multicolinearidade não viola nenhuma das hipóteses de uma regressão, já que estimativas consistentes, não viesadas os erros padrão serão estimados corretamente.

Os resultados da correlação estão demonstrados na Figura 04.

	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X16	
Covariância	X1	,304	,144	,058	-1,024	102,719	64,130	1378,601	1370,885	-2,768	1697,381	2302008,583	,066	-,931	-16,915	-149,683	-734,048
	X2	,144	33,586	33,449	-359,164	-401,782	184,820	18772,423	18690,561	48,259	25845,913	4242329,540	-,404	4,941	129,175	577,606	-2227,061
	X3	,058	33,449	33,434	-335,639	-458,909	154,557	17841,122	17767,651	50,438	24478,422	3383627,501	-,432	5,519	135,166	625,017	-1885,815
	X4	-1,024	-359,164	-335,639	2246913,031	72749,678	-44066,173	3184993,856	3167416,048	-8174,598	4775414,032	-464834237,5	97,477	1302,559	36246,735	175707,262	333522,901
	X5	102,719	-401,782	-458,909	72749,678	4767768,152	117441,162	4625378,669	4608438,933	2375,068	6359847,930	221089073,47	1080,058	-1318,340	112871,487	305606,574	-1359611,347
	X6	64,130	184,820	154,557	-44066,173	117441,162	2755088,710	-2932366,254	-2916381,921	-13681,426	-4418135,886	-135248959,2	122,753	-1784,696	-42732,390	-216290,715	-29044393,80
	X7	1378,601	18772,423	17841,122	3184993,856	4625378,669	-2932366,254	2125474557,3	2122454761,3	-314425,662	2994947445,9	8408601170,4	4503,151	-76055,587	-1806402,608	-8597141,707	39445613,126
	X8	1370,885	18690,561	17767,651	3167416,048	4608438,933	-2916381,921	2122454761,3	2119461752,9	-313216,774	2989982906,3	8394965737,5	4476,472	-75800,013	-1800462,688	-8570862,312	39262439,949
	X9	-2,768	48,259	50,438	-8174,598	2375,068	-13681,426	-314425,662	-313216,774	1585,184	-394947,998	-32758996,75	-6,534	57,400	1120,295	8890,719	155881,421
	X10	1697,381	25845,913	24478,422	4775414,032	6359847,930	-4418135,886	2994947445,9	2989982906,3	-394947,998	4427545358,4	12857414669	6357,262	-103341,781	-2454526,521	-11704303,23	57243877,732
	X11	2302008,583	4242329,540	3383627,501	-464834237,5	221089073,47	-135248959,2	8408601170,4	8394965737,5	-32758996,75	12857414669	2,909E+14	1585779,038	1235751,966	-430290956,9	-378954477,2	765373935,13
	X12	,066	-,404	-,432	97,477	1080,058	122,753	4503,151	4476,472	-6,534	6357,262	1585779,038	,617	-2,164	-41,298	-167,655	-1380,963
	X13	-,931	4,941	5,519	1302,559	-1318,340	-1784,696	-76055,587	-75800,013	57,400	-103341,781	1235751,966	-2,164	468,368	9144,937	46119,419	20933,702
	X14	-16,915	129,175	135,166	36246,735	112871,487	-42732,390	-1806402,608	-1800462,688	1120,295	-2454526,521	-430290956,9	-41,298	9144,937	347440,498	1005927,228	497371,511
	X15	-149,683	577,606	625,017	175707,262	305606,574	-216290,715	-8597141,707	-8570862,312	8890,719	-11704303,23	-378954477,2	-167,655	46119,419	1005927,228	4979499,097	2538660,689
	X16	-734,048	-2227,061	-1885,815	333522,901	-1359611,347	-29044393,80	39445613,126	39262439,949	155881,421	57243877,732	765373935,13	-1380,963	20933,702	497371,511	2538660,689	307304362,71
Correlação	X1	1,000	,045	,018	-,001	,085	,070	,054	,054	-,126	,046	,245	,153	-,078	-,052	-,122	-,076
	X2	,045	1,000	,998	-,041	-,032	,019	,070	,070	,209	,067	,043	-,089	,039	,038	,045	-,022
	X3	,018	,998	1,000	-,039	-,036	,016	,067	,067	,219	,064	,034	-,095	,044	,040	,048	-,019
	X4	-,001	-,041	-,039	1,000	,022	-,018	,046	,046	-,137	,048	-,018	,083	,040	,041	,053	,013
	X5	,085	-,032	-,036	,022	1,000	,032	,046	,046	,027	,044	,006	,630	-,028	,088	,063	-,036
	X6	,070	,019	,016	-,018	,032	1,000	-,038	-,038	-,207	-,040	-,005	,094	-,050	-,044	-,058	-,998
	X7	,054	,070	,067	,046	,046	-,038	1,000	1,000	-,171	,976	,011	,124	-,076	-,066	-,084	,049
	X8	,054	,070	,067	,046	,046	-,038	1,000	1,000	-,171	,976	,011	,124	-,076	-,066	-,083	,049
	X9	-,126	,209	,219	-,137	,027	-,207	-,171	-,171	1,000	-,149	-,048	-,209	,067	,048	,100	,223
	X10	,046	,067	,064	,048	,044	-,040	,976	,976	-,149	1,000	,011	,122	-,072	-,063	-,079	,049
	X11	,245	,043	,034	-,018	,006	-,005	,011	,011	-,048	,011	1,000	,118	,003	-,043	-,010	,003
	X12	,153	-,089	-,095	,083	,630	,094	,124	,124	-,209	,122	,118	1,000	-,127	-,089	-,096	-,100
	X13	-,078	,039	,044	,040	-,028	-,050	-,076	-,076	,067	-,072	,003	-,127	1,000	,717	,955	,055
	X14	-,052	,038	,040	,041	,088	-,044	-,066	-,066	,048	-,063	-,043	-,089	,717	1,000	,765	,048
	X15	-,122	,045	,048	,053	,063	-,058	-,084	-,083	,100	-,079	-,010	-,096	,955	,765	1,000	,065
	X16	-,076	-,022	-,019	,013	-,036	-,998	,049	,049	,223	,049	,003	-,100	,055	,048	,065	1,000

Figura 04: Matriz de Covariância e Correlação

Fonte: Resultado da Pesquisa, 2021

Analisando os dados da Figura 04, pode-se identificar que as variáveis X_2 e X_3 ; X_6 e X_{16} ; X_7 e X_8 ; X_7 e X_{10} ; X_8 e X_{10} , bem como X_{13} e X_{15} , possuem grau de correlação forte (correlação próxima a 1), portanto elas foram excluídas do rol de variáveis, exceto a variável independente X_{15} . A presença de autocorrelação aponta para casos de multicolinearidade, pois, é habitual para dados de séries temporais e para cortes transversais. Na opinião de Gujarati (2011), a primeira providência para resolver o problema de multicolinearidade é excluir as variáveis.

Entretanto, para testar homogeneidade das matrizes covariância-correlação e para que a estimativa conjunta da variância residual possa ser obtida, já que o pressuposto de que a matriz para cada um dos grupos em estudo, em relação a cada uma das p -variáveis, é de uma mesma população de variância-covariância, não pode ocorrer violação sob pena de comprometer a robustez da função discriminante. Para esse teste foi utilizado o M de Box. As hipóteses do teste são:

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

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

A estatística do teste é dada por:

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

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

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

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

Dessa forma, se a dimensão de todas as amostras for igual, a função discriminante pode ser considerada robusta relativamente à não violação do pressuposto de homogeneidade das matrizes de variância-covariância. Nesse caso, aceita-se a hipótese H_0 de que as variáveis possuem a mesma variância. O resultado está representado na figura 05.

M de Box		2426,657
Z	Aprox.	14,607
	df1	120
	df2	10429,613
	Sig.	<,001

Figura 05: Teste de M de Box

Fonte: Resultado da Pesquisa, 2021

Como se observa no resultado do teste M de Box, o nível de significância foi $<0,001$, portanto inferior a 0,05. Se o p -valor for maior que 0,05, aceita-se a hipótese nula, o que indica

que os dados estão bons e que não existe diferença entre a matriz de covariância nas duas amostras. Em que pese o recomendado $p\text{-valor} < 0,05$, o nível de significância obtido foi inferior, entretanto, isso não afeta a continuidade da geração da função discriminante. Quando o Teste M de Box indica violação dessa premissa, nível de significância de 0,05, o resultado do teste é menor e o *software* não deixou de gerar todas as demais etapas, tem-se o indicativo de que as violações estatísticas não estão inviabilizando o estudo (CORRAR et al. 2014). No caso desse estudo, não houve inconsistências nas demais etapas.

Para testar a significância da função discriminante, o *Software IBM SPSS Statistics* gera as saídas de autovalores e correlação canônica e o Lambda de Wilks. Os resultados estão representados nas figuras 06 e 07:

Função	Autovalor	% de variância	% cumulativa	Correlação canônica
1	1,508 ^a	100,0	100,0	,775

Fonte: SPSS Statistics.

a. As primeiras 1 funções discriminantes canônicas foram usadas na análise.

Figura 06: Autovalores e Correlação Canônica

Fonte: Resultado da Pesquisa, 2021

A pesquisa, por contar somente com dois grupos de estudos, gera apenas uma função discriminante (n-1). O autovalor, que é a medida relativa de como diferentes são os grupos, apresenta um valor associado a essa função de 1,508 que responde por 100% da variância explicada. Portanto, o autovalor indica o grau de superioridade entre as funções e que estas têm a sua importância. O poder explicativo é dado pela Correlação Canônica que mede o alcance da associação entre os escores discriminantes e os grupos e, possuem o mesmo poder explicativo do R^2 de uma análise de regressão. Elevando o resultado ao quadrado tem-se a medida do poder explicativo da função. Neste estudo, o resultado é de 0,775 que, elevado ao quadrado, indica que 60% da variável dependente são explicadas pelo modelo (CORRAR et al. 2014).

Lambda de Wilks				
Teste de funções	Lambda de Wilks	Qui-quadrado	df	Sig.
1	,399	46,435	15	<,001

Figura 07: Resultado do Lambda de Wilks

Fonte: Resultado da Pesquisa, 2021

O resultado de 0,399 de Lambda de Wilks para um Qui-quadrado de 46,435 e p-valor 0,001. Conforme figura 07, pode-se afirmar que a função discriminante é altamente

significativa. Para um p-valor $> 0,05$ indica essa condição. Já o Lambda de Wilks, quanto mais próximo de “zero” for seu valor, mais intensa será a diferença entre as médias dos grupos, indicando que a função tem alta capacidade de discriminar os elementos entre os grupos (CORRAR et al. 2014).

Observa-se na figura 08 que todos os índices que se encontram com o p-valor zerado são os mesmos evidenciados nas análises feitas nas saídas anteriores e corroboram os apontamentos feitos.

Função 1	
X1	-1,521
X2	-,061
X3	,075
X4	,000
X5	,000
X6	,002
X7	,000
X9	-,001
X10	,000
X11	,000
X12	-,509
X13	,053
X14	,000
X15	-,001
X16	,000
(Constante)	1,206

Figura 08: Coeficientes da Função Discriminante

Fonte: Resultado da Pesquisa, 2021

Após os testes de significância do modelo, o Software *IBM SPSS Statistics* fornece a função discriminante conforme a Figura 08. Observa-se que as variáveis X₄, X₅, X₇, X₁₀, X₁₁, X₁₄ e X₁₆ apresentam coeficientes iguais a “zero”, dessa forma, entende-se que elas devem ser descartadas pelo fato que levarão a um resultado nulo quando aplicadas.

Processado		60
Excluídos	Códigos de grupo omissos ou fora do intervalo	0
	Pelo menos uma variável discriminante omissa	0
Usado em saída		60

Figura 09: Resumo de Processamento de Classificação dos Agrupamentos
Fonte: Resultado da Pesquisa, 2021

Nessa saída da figura 09, têm-se as informações referentes ao processamento dos agrupamentos na sua totalidade. Observa-se que o código de grupo omissos ou fora do intervalo encontra-se zerado, assim também, o outro apontamento é que pelo menos uma variável possui discriminante omissa, portanto, não houve exclusão ou omissão.

Resultados da classificação^a

		Associação ao grupo prevista			Total
		EMPRESAS	0	1	
Original	Contagem	0	27	3	30
		1	2	28	30
	%	0	90,0	10,0	100,0
		1	6,7	93,3	100,0

Fonte: SPSS Statistics.

a. 91,7% de casos agrupados originais classificados corretamente.

Figura 10: Resultado da Classificação
Fonte: Resultado da Pesquisa, 2021

No resultado da classificação demonstrado na figura 10, está a quantidade de empresas classificadas corretamente em cada grupo e, respectivamente, as que foram classificadas de forma errada, seguida do percentual de cada grupo e, por fim, do percentual geral de classificação que foi de 91,7% dos casos classificados corretamente.

Em conclusão, nessa primeira análise processada pelo *Software IBM SPSS Statistics* com todas as variáveis independentes, optou-se em reduzir a amostra levando em consideração os resultados das saídas já mencionados. Essa decisão tem suporte em Gujarati (2011), Hair et al. (2005) e em Corrar et al. (2014). As exclusões de variáveis são:

- Resultado da saída do teste de igualdade de médias de grupos em que o Lambda de Wilks, quanto mais próximo de 1,000 é pior, igualmente, a significância de que o recomendado para o p-valor seja menor que 0,05;

- b) Exclusão das variáveis com grau de correlação forte evidenciado na figura 04 de covariância e correlação; a exclusão se deu para eliminar problemas de multicolinearidade; e
- c) Eliminação das variáveis com coeficientes “zerados” na figura 08, resultado da função discriminante, como já mencionado, se utilizadas, redundará em resultado nulo.

Dessa forma, mediante as exclusões de algumas variáveis independentes, com o propósito de melhorar a saída de dados e obter uma função discriminante mais robusta, restaram as seguintes variáveis independentes: Liquidez Geral (X_1), Margem Bruta (X_9), Giro do Ativo (X_{12}), Giro do Patrimônio Líquido (X_{13}) e Capital de Terceiro (X_{15}).

Portanto, com base nas 5 variáveis independentes selecionadas, os dados foram alimentados no *Software IBM SPSS Statistics*, cujos resultados estão a seguir demonstrados, conforme figuras 11 a 20.

Casos não ponderados		N	Porcentagem
Válido		60	100,0
Excluídos	Códigos de grupo omissos ou fora do intervalo	0	,0
	Pelo menos uma variável discriminante omissa	0	,0
	Códigos de grupo omissos ou fora do intervalo e pelo menos uma variável discriminadora omissa	0	,0
	Total	0	,0
Total		60	100,0

Figura 11: Resumo de Processamento de Caso de Análise

Fonte: Resultado da Pesquisa, 2021

O resumo do processamento, conforme figura 11, com apenas uma saída contendo informações dos dados das 60 empresas que compõem a amostra, obteve um coeficiente de validação de 100%.

EMPRESAS		Média	Erro Desvio	N válido (de lista)	
				Não ponderado	Ponderado
0	X1	,2749080985	,2410089863	30	30,000
	X9	41,20996845	53,28558182	30	30,000
	X12	,5189939094	,8456048014	30	30,000
	X13	-7,70340440	30,40867205	30	30,000
	X15	-1034,53827	3087,196270	30	30,000
1	X1	1,220508974	,7416847467	30	30,000
	X9	25,70357408	18,19381368	30	30,000
	X12	,8440707983	,7208016183	30	30,000
	X13	2,834600675	3,471115660	30	30,000
	X15	281,6002433	654,3832103	30	30,000
Total	X1	,7477085363	,7254417882	60	60,000
	X9	33,45677127	40,24235868	60	60,000
	X12	,6815323539	,7960559121	60	60,000
	X13	-2,43440186	22,10571162	60	60,000
	X15	-376,469014	2309,869233	60	60,000

Figura 12: Médias e Desvio-padrão das Variáveis Independentes
Fonte: Resultado da Pesquisa, 2021

A figura 12 apresenta o resultado da estatística descritiva (média e desvio-padrão), os quais servem para verificar qual variável independente tem maior ou menor média e desvio-padrão; é um indicativo de qual delas pode ser mais significativa no modelo, ou seja, aquela que tem maior variabilidade.

	Lambda de Wilks	Z	df1	df2	Sig.
X1	,568	44,107	1	58	<,001
X9	,962	2,275	1	58	,137
X12	,958	2,568	1	58	,114
X13	,942	3,556	1	58	,064
X15	,917	5,218	1	58	,026

Figura 13: Teste de Igualdade de Médias de Grupos
Fonte: Resultado da Pesquisa, 2021

O teste de igualdade de médias de grupos, conforme figura 13, é o resultado que demonstra se a estatística consegue separar os grupos. Se $p\text{-valor} > 0,05$, então é significativo, ou seja, consegue separar os grupos. Nesse caso, somente a variável X_1 apresenta $p\text{-valor} > 0,05$ e o menor Lambda de Wilks. Em que pese as demais variáveis não atenderem a essa condição, o modelo não foi prejudicado no seu poder preditivo.

		X1	X9	X12	X13	X15
Covariância	X1	,304	-2,768	,066	-,931	-149,683
	X9	-2,768	1585,184	-6,534	57,400	8890,719
	X12	,066	-6,534	,617	-2,164	-167,655
	X13	-,931	57,400	-2,164	468,368	46119,419
	X15	-149,683	8890,719	-167,655	46119,419	4979499,097
Correlação	X1	1,000	-,126	,153	-,078	-,122
	X9	-,126	1,000	-,209	,067	,100
	X12	,153	-,209	1,000	-,127	-,096
	X13	-,078	,067	-,127	1,000	,955
	X15	-,122	,100	-,096	,955	1,000

Figura14: Matriz de Covariância e Correlação
Fonte: Resultado da Pesquisa, 2021

Essa é uma matriz de covariância-correlação evidenciada na figura 14. Observa-se que os problemas de autocorrelação foram eliminados com a exclusão das variáveis, entretanto, a correlação entre as variáveis independentes X_{13} e X_{15} , mesmo tendo um grau muito forte de correlação positiva, optou-se em não as excluir tendo em vista que isso acarretaria prejuízos no resultado do modelo da função discriminante, assim o modelo não foi prejudicado.

Para testar a homogeneidade das matrizes covariância-correlação de forma que a estimativa conjunta da variância residual possa ser obtida, não pode ocorrer violação sob pena de comprometer a solidez da função discriminante. Para esse teste, foi utilizado o M de Box cujo resultado está na figura 15.

M de Box	251,713
Z	Aprox. 15,219
	df1 15
	df2 13544,526
	Sig. <,001

Fonte: SPSS Statistics.
 Testa hipótese nula de matrizes de covariâncias de população igual.

Figura 15: Teste de M de Box
Fonte: Resultado da Pesquisa, 2021

Se a dimensão de todas as amostras for igual, a função discriminante pode ser considerada robusta relativamente à não violação do pressuposto de homogeneidade das matrizes de variância-covariância. Nesse caso, se o p-valor de M de Box for maior que 0,05, aceita-se a hipótese H_0 de que as variáveis possuem a mesma variância. Essa condição indica

que os dados estão bons e que não existe diferença na matriz de covariância entre as duas amostras.

Como se observa no resultado do teste M de Box, o nível de significância foi $<0,001$, portanto inferior a 0,05. Em que pese o recomendado p-valor $< 0,05$, o nível de significância obtido foi inferior, entretanto, isso não afeta a continuidade da geração da função discriminante, porque, quando o Teste M de Box indica violação dessa premissa, nível de significância de 0,05, resultado do teste menor e o *software* não deixou de gerar todas as demais etapas, tem-se o indicativo de que as violações estatísticas não estão inviabilizando o estudo (Corrar et al. 2014). No caso desse estudo, não houve inconsistências nas demais etapas.

Função	Autovalor	% de variância	% cumulativa	Correlação canônica
1	1,015 ^a	100,0	100,0	,710

Fonte: SPSS Statistics.

a. As primeiras 1 funções discriminantes canônicas foram usadas na análise.

Figura 16: Autovalores e Correlação Canônica

Fonte: Resultado da Pesquisa, 2021

No presente estudo, tem-se uma amostra com 2 agrupamentos, portanto só foi gerada uma Função Discriminante que é o número de grupos ou variáveis dependentes menos 1 (n-1).

Nesse caso, o modelo, conforme resultados da figura 16, consegue explicar em 100% a variação dos dados com apenas uma Função Discriminante (autovalor = 1,015). O autovalor indica o grau de superioridade entre funções. Como se trata de modelo com uma única função, entende-se que esta tem sua importância. O poder explicativo é dado pela correlação canônica, tem o mesmo poder explicativo do R^2 de uma análise de regressão. Elevando o valor de 0,710 ao quadrado, tem-se a medida do poder explicativo da Função que, nesse caso, é de 50,41%, logo, o grau de confiabilidade da função ainda é aceitável (CORRAR et al. 2014).

Teste de funções	Lambda de Wilks	Qui-quadrado	df	Sig.
1	,496	38,876	5	<,001

Figura 17: Resultado do Lambda de Wilks

Fonte: Resultado da Pesquisa, 2021

Nessa saída, é apresentado o teste de Wilks' Lambda para testar a Função Discriminante. Nesse caso, foi significativo, pois o p-valor é menor que 0,05, conforme figura 17.

O Lambda de Wilks, quanto mais próximo de 1, torna-o não significativo; nesse caso, 0,496 é significativo. De forma contrária, o Lambda de Wilks, quanto mais próximo de 0 for seu valor, mais intensa será a diferença entre as médias dos grupos, indicando que a Função tem alta capacidade de discriminar os elementos entre o grupo (CORRAR et al. 2014).

Função 1	
X1	1,679
X9	-,003
X12	,062
X13	-,040
X15	,001
(Constante)	-1,068

Figura 18: Coeficientes de Função Discriminante Canônica
Fonte: Resultado da Pesquisa, 2021

Na figura 18, têm-se os coeficientes da Função Discriminante Canônica, ou seja, **Modelo de Previsão de Insolvência Aranha & Gondrige**, portanto, o trabalho desenvolvido atingiu seus objetivos, cuja função para previsão de insolvência é:

$$FI = - 1,068 + 1,679*X_1 - 0,003*X_9 + 0,062*X_{12} - 0,040*X_{13} + 0,001*X_{15}$$

O Modelo de Previsão de Insolvência Aranha & Gondrige é composto por uma constante de -1,068, por conseguinte temos “os pesos ou p-valores” atribuídos pelo Software SPSS com suas respectivas variáveis independentes, sendo que +1,679 está para X₁ Liquidez Geral, -0,003 está para X₉ Margem bruta, + 0,062 está para X₁₂ Giro do Ativo, -0,040 está para X₁₃ Giro do Patrimônio Líquido e, + 0,001 está para X₁₅ Participação Capitais Terceiros.

Processado		60
Excluídos	Códigos de grupo omissos ou fora do intervalo	0
	Pelo menos uma variável discriminante omissa	0
Usado em saída		60

Figura 19: Resumo de Processamento de Classificação
Fonte: Resultado da Pesquisa, 2021

Nesse resumo da saída do *SPSS*, demonstrado na figura 19, têm-se as informações do resultado do processamento das variáveis. Nota-se que não houve exclusão de nenhuma delas, tendo sido processados 100% dos dados das 60 companhias.

Dessa maneira, na figura 20 está o resultado da classificação de modo que o grupo com 30 empresas “0” que corresponde a 100% do primeiro grupo, classificou 28 corretamente, obtendo 93,3% e apenas 2 foram classificadas erradas, ou seja, foram consideradas como grupo “1”, perfazendo 6,7%. Do segundo grupo com 30 empresas “1” classificou 26 corretamente, atingindo 86,7% e 4 foram classificadas como se do grupo “0”, correspondendo a 13,3%.

Resultados da classificação^a

Original	Contagem	Associação ao grupo prevista		Total	
		EMPRESAS	0		1
		0	28	2	30
		1	4	26	30
	%	0	93,3	6,7	100,0
		1	13,3	86,7	100,0

Fonte: SPSS Statistics.

a. 90,0% de casos agrupados originais classificados corretamente.

Figura 20: Resultados da Classificação

Fonte: Resultado da Pesquisa, 2021

Sendo assim, somam-se as porcentagens de acerto dos dois grupos e divide-se por dois chegando a uma média final de casos agrupados e classificados corretamente de 90%. Portanto, pode-se afirmar que a função discriminante é relevante, robusta e tem alto poder discriminatório, pois apresenta um poder explicativo de 90%, ou seja, é um bom modelo para classificar empresas insolventes das solventes.

4. DISCUSSÃO DO RESULTADO

Diante das análises estatísticas, com a utilização do *software IBM SPSS Statistics*, obteve-se uma Função Discriminante com grau de classificação de 90%, conforme figura 20. Com apenas 05 variáveis independentes da amostra, decidiu-se submetê-las ao teste para medir sua capacidade de discriminação, utilizando-se, para isso, da planilha eletrônica *Microsoft Excel*[®].

Para testar o poder de discriminação do modelo, valeram-se como parâmetro dos procedimentos utilizados por Kassai e Kassai (1999) em seu trabalho denominado “Desvendando Termômetro de Kanitz”, conforme os passos a seguir descritos:

1º Passo: obter os índices das variáveis e alimentar a planilha;

2º Passo: criar uma nova coluna na planilha do Excel® com os p valores da função discriminante fornecida pelo *Software IBM SPSS Estatistics*, chamada “Escore Discriminante” e calcular o “Ponto de Corte”;

3º Passo: analisar o “Grau de Precisão” do modelo;

4º Passo: construir a “Curva de Gauss” e os “Pontos de Separação do Modelo”.

Portanto, diante desses passos seguem os procedimentos feitos na amostra para validação do modelo de previsão de insolvência Aranha & Gondrige.

- 1º Passo: obter os índices das variáveis e alimentar a planilha;

Conforme já demonstrado nesse estudo, foi atribuído para agrupamentos “0” para as empresas insolventes e “1” para as empresas solventes e, para as variáveis independentes Liquidez Geral (X_1), Margem Bruta (X_9), Giro do Ativo (X_{12}), Giro do Patrimônio Líquido (X_{13}) e Capital de Terceiros (X_{15}). Sendo esses os dados alimentados na planilha do Excel®:

- 2º Passo: criar uma nova coluna na planilha do Excel® onde se denominou de “Escore Discriminante” com os p valores da função discriminante:

FI = -1,068 + (1,679*X₁) - (0,003*X₉) + (0,062*X₁₂) - (0,04*X₁₃) + (0,001*X₁₅) Função essa fornecida pelo *Software IBM SPSS Estatistics* e, logo após, calcular o “ponto de corte”.

Para calcular o ponto de corte, usou-se o próprio Excel®, utilizando a média aritmética simples para efetuar os cálculos das empresas insolventes “0” e das empresas solventes “1”, de acordo com a Tabela 15. O Excel® cria uma saída, conforme Tabela 16, na qual foi utilizada apenas a média aritmética simples que se encontra na Tabela 15: empresas “0” = -1,42 e média aritmética simples das empresas “1” = 1,12. De posse dessas médias, somam-se as duas e divide por dois $(-1,42+1,12) / 2 = -0,15$ ponto de corte. Contudo, Kassai et al. (1999) comentam que “existem outras técnicas estatísticas para refinar o cálculo do ponto de corte e aprimorar as análises discriminantes, por exemplo o cálculo da Distância Euclidiana, Distância de Mahalanobis, análise multivariante etc”.

Tabela 15: Resultado da Estatística Descritiva para Média Empresas “0” e Média Empresas “1”

	Média Empresas “0”		Média Empresas “1”
Média	-1,42428368	Média	1,124672451
Erro padrão	0,342113202	Erro padrão	0,227221612
Mediana	-1,185739637	Mediana	0,7251642
Modo	#N/D	Modo	#N/D
Desvio padrão	1,873831182	Desvio padrão	1,244544026
Variância da amostra	3,511243299	Variância da amostra	1,548889832
Curtose	6,615353672	Curtose	2,104809599
Assimetria	-1,325201871	Assimetria	1,44759578
Intervalo	11,68596769	Intervalo	5,495903022
Mínimo	-8,067528024	Mínimo	-0,504789395
Máximo	3,618439668	Máximo	4,991113626
Soma	-42,72851041	Soma	33,74017353
Contagem	30	Contagem	30

Fonte: o Autor, 2021

- 3º Passo: analisar o “Grau de Precisão” do modelo.

Nessa etapa, o ponto de corte já está definido em “-0,15”, fornecido pelos cálculos já mencionados, o qual servirá de parâmetro para classificar as empresas comparando a célula que se encontra na Tabela 16 “Classificação pelo Excel[®]” com a célula “Empresas” e, logo, tem-se o “Grau de Precisão” do modelo, conforme tabela a seguir:

Tabela 16: Variáveis das Empresas, Escore Discriminante e Classificação Excel[®]

Empresas	X ₁	X ₉	X ₁₂	X ₁₃	X ₁₅	Escore Discriminante	Classificação Excel
0	0,1	4,3	0,1	0,0	-108,9	-1,07	0
0	0,0	12,7	0,0	0,0	-521,5	-1,61	0
0	0,6	22,7	0,6	-30,8	-4.895,2	-3,71	0
0	0,0	100	0,0	0,0	-103,7	-1,41	0
0	0,0	100	0,0	0,0	-100,1	-1,47	0
0	0,2	58,9	0,0	0,0	-157,0	-1,07	0
0	0,5	100,0	0,0	0,0	-992,2	-1,59	0
0	0,0	100,0	0,0	0,0	-358,4	-1,67	0
0	0,5	13,1	1,1	-147,8	-13.810,9	-8,07	0
0	0,3	-0,2	0,3	-0,2	-173,1	-0,67	0
0	0,3	-3,8	0,8	-0,9	-210,5	-0,73	0
0	0,0	112	0,0	0,0	-168,0	-1,49	0
0	0,4	-140,3	0,0	-0,2	-867,1	-0,76	0
0	0,1	90,7	0,1	0,0	-112,0	-1,34	0
0	0,3	23,5	0,5	-0,3	-159,7	-0,70	0
0	0,3	33,1	0,9	-64,3	-7.369,0	-5,42	0
0	0,2	8,4	1,0	-0,9	-183,7	-0,92	0
0	0,0	100,0	0,0	0,0	-103,6	-1,41	0
0	0,9	3,6	0,0	-0,9	-3.496,2	-3,01	0

0	0,4	2,9	0,5	-0,4	-190,3	-0,49	0
0	0,6	46,0	4,3	-15,3	-459,0	0,21	1
0	0,7	6,6	0,7	37,6	4.934,0	3,62	1
0	0,4	39,3	0,8	-1,2	-258,5	-0,69	0
0	0,1	100	0,0	0,0	-112,5	-1,30	0
0	0,3	16,2	0,2	-0,1	-161,3	-0,74	0
0	0,1	31,4	0,6	-0,4	-163,1	-1,05	0
0	0,0	100,0	0,1	0,0	-102,6	-1,42	0
0	0,0	100,0	0,0	0,0	-101,3	-1,45	0
0	0,4	38,9	1,6	-3,7	-326,9	-0,58	0
0	0,3	16,3	1,3	-1,4	-203,8	-0,74	0
1	1,0	9,7	2,0	9,9	396,6	0,69	1
1	0,4	55,1	0,3	0,9	183,1	-0,48	0
1	0,6	20,9	0,7	3,6	452,0	0,28	1
1	0,7	10,3	0,4	15,7	3.683,4	3,12	1
1	1,1	22,5	0,9	1,6	72,4	0,71	1
1	1,3	29,4	0,2	0,7	167,7	1,17	1
1	1,1	18,3	0,1	0,2	76,5	0,87	1
1	1,1	97,1	0,0	0,0	36,7	0,47	1
1	2,3	32,0	0,9	1,2	42,4	2,76	1
1	0,9	25,0	0,5	2,7	397,3	0,69	1
1	1,4	48,8	0,2	0,4	109,0	1,26	1
1	1,1	21,8	0,6	2,5	286,1	0,99	1
1	0,7	17,9	1,0	4,7	360,3	0,33	1
1	1,0	44,3	1,0	2,9	181,4	0,65	1
1	1,0	15,9	0,6	1,0	64,4	0,70	1
1	1,0	18,1	0,6	1,6	155,2	0,73	1
1	0,9	21,0	0,6	1,2	89,3	0,44	1
1	0,4	19,4	0,6	1,6	193,0	-0,23	0
1	0,2	36,7	0,3	1,0	282,1	-0,50	0
1	1,1	6,2	3,7	10,7	191,3	0,75	1
1	2,1	10,6	2,2	3,6	65,2	2,56	1
1	0,6	19,3	1,1	4,9	337,4	0,02	1
1	2,6	22,0	0,7	0,8	24,1	3,28	1
1	1,0	5,1	0,6	0,9	45,7	0,72	1
1	1,4	20,9	0,8	1,6	107,1	1,31	1
1	3,7	43,8	0,9	1,1	27,2	4,99	1
1	2,5	23,2	0,6	0,8	24,6	3,09	1
1	1,2	13,2	0,8	2,0	155,0	1,02	1
1	1,2	27,2	1,0	2,4	146,0	1,03	1
1	0,8	15,4	1,5	2,8	95,5	0,31	1

Fonte: o Autor, 2021

Analisando as saídas dos dados da tabela 16, quanto ao “grau de precisão” do modelo, pode-se verificar que, do total da amostra de 60 empresas insolventes “0” e solventes “1”, o

modelo classificou 4 companhias erradas e 1, no rol de sombreamento ou penumbra, ou seja, encontra-se indefinida, sendo assim, apresentou um grau de precisão de 93,33%.

- 4º Passo: construir a “Curva de Gauss” e os “Pontos de Separação do Modelo”.

Após calculado o ponto de corte em -0,15 e o modelo ter um “Grau de Precisão” de 93,33%, pode-se considerá-lo de um nível excelente, portanto é possível agora construir a “Curva de Gauss”, conforme Figura 21.

Consoante a Tabela 17, foram obtidas as médias aritméticas de -1,42 e o desvio-padrão de 1,87 para as empresas insolventes “0” e uma média aritmética de 1,12 e um desvio-padrão de 1,24 para as empresas solventes “1”. Por isso, pode-se agora calcular o ponto inicial e final da curva de Gauss das empresas “0”, onde a média aritmética de -1,42 de que irá subtrair o desvio-padrão 1,87, chegando ao resultado de -3,29, que é o primeiro ponto da curva de Gauss. Para calcular o segundo ponto, parte-se da média aritmética de -1,42 e soma-se com o desvio-padrão de 1,87 e a resultante para o segundo ponto será igual a 0,45.

Para calcular o ponto inicial e o final da curva de Gauss das empresas “1”, parte-se da média aritmética de 1,12 da Tabela 17 que, ao subtrair o desvio-padrão 1,24, chega-se ao resultado de -0,12, que é o primeiro ponto da curva de Gauss. Para calcular o segundo ponto, parte-se da média aritmética de 1,12 e soma-se com o desvio-padrão de 1,24, sendo a resultante o segundo ponto que é 2,36.

Tabela 17: Média Empresa “0” e Média Empresa “1”

Média Empresas “0”		Média Empresas “1”	
Média	-1,42428368	Média	1,124672451
Erro padrão	0,342113202	Erro padrão	0,227221612
Mediana	-1,185739637	Mediana	0,7251642
Modo	#N/D	Modo	#N/D
Desvio padrão	1,873831182	Desvio padrão	1,244544026
Variância da amostra	3,511243299	Variância da amostra	1,548889832
Curtose	6,615353672	Curtose	2,104809599
Assimetria	-1,325201871	Assimetria	1,44759578
Intervalo	11,68596769	Intervalo	5,495903022
Mínimo	-8,067528024	Mínimo	-0,504789395
Máximo	3,618439668	Máximo	4,991113626
Soma	-42,72851041	Soma	33,74017353
Contagem	30	Contagem	30

Fonte: o Autor, 2021

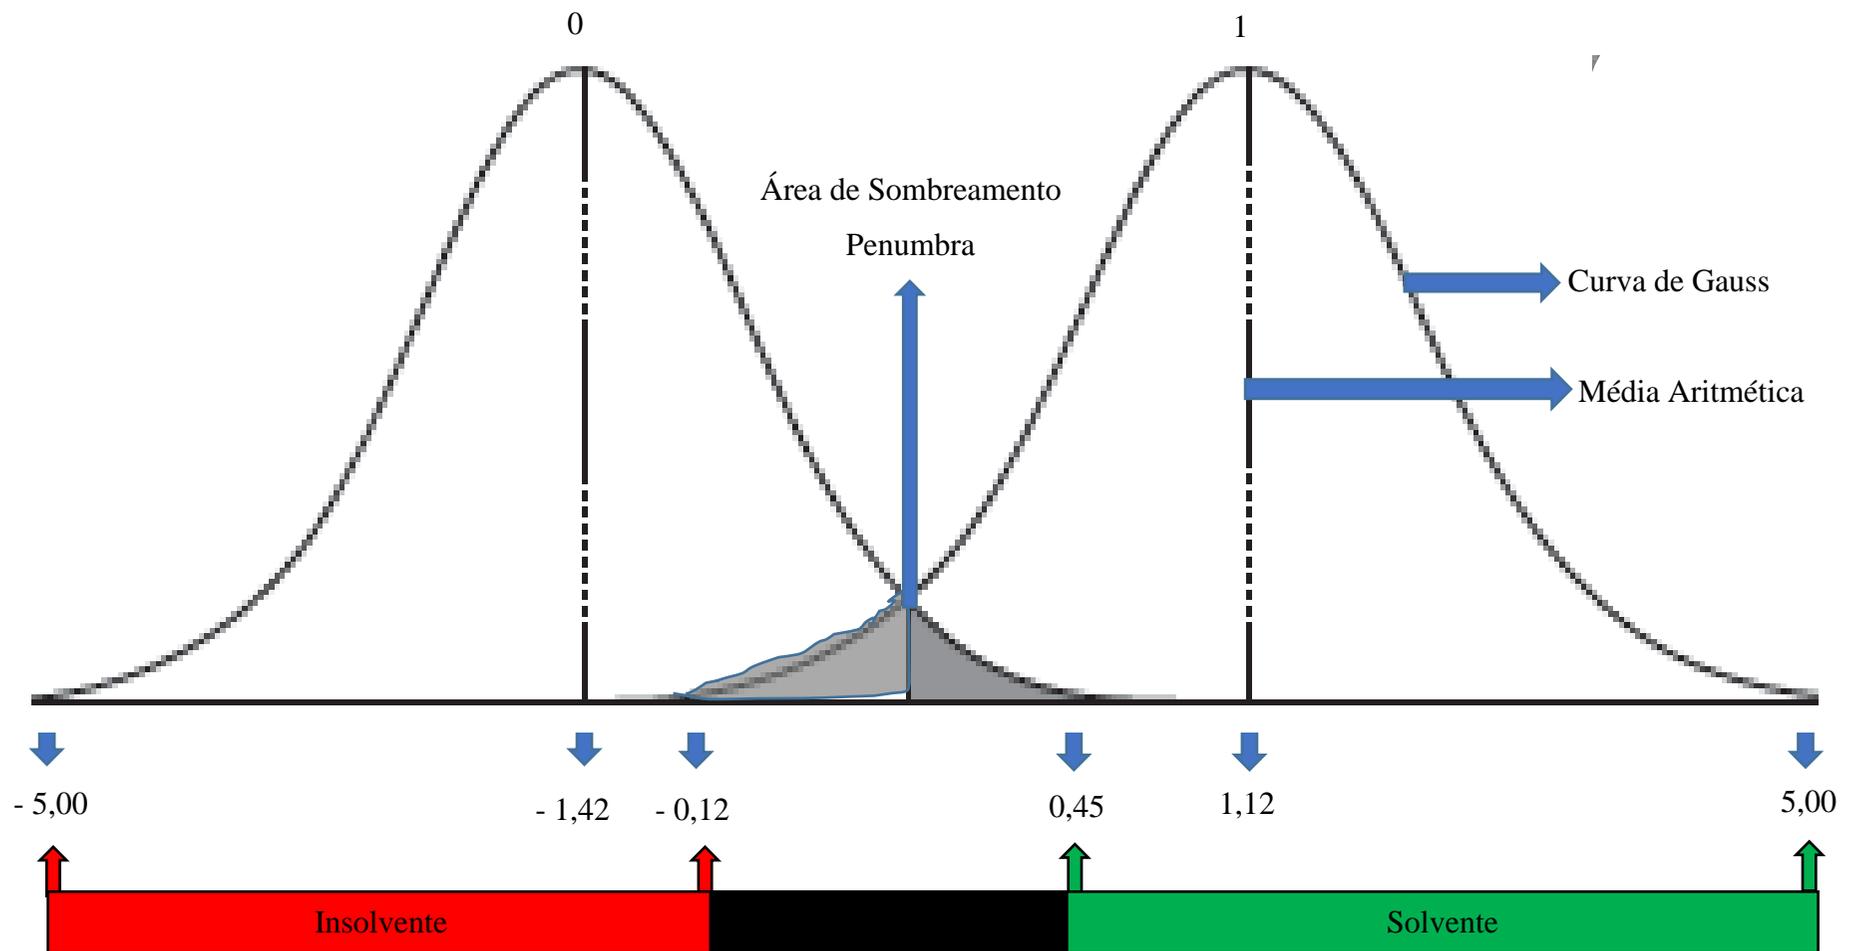


Figura 21: Curva de Gauss e os Pontos de Separação do Modelo

Fonte: Gujarati (2011), adaptada pelo autor, 2021

Conforme construção da curva de Gauss e os pontos de separação do modelo demonstrado na figura 21, optou-se em ampliar os valores dos extremos dos pontos de separação de (-3,29 para -5,00) e (2,36 para 5,00), para melhor entendimento e padronização do **Modelo de Previsão Aranha & Gondrige**.

Além disso, tem-se também, nos outros dois pontos da curva de Gauss, uma área de sombreamento a qual Kanitz chamou em seu modelo de “penumbra”, que se encontra entre 0,12 a 0,45.

4.1 Validação do Modelo Aranha & Gondrige

Nesse tópico, ocorreu a validação da função discriminante do Modelo de previsão Aranha & Gondrige, que se obteve como saída, através da análise dos dados no *software IBM SPSS Estatistics*, com um poder classificatório de 90%, conforme evidenciado na figura 20.

$$FI = -1,068 + 1,679 * X_1 - 0,003 * X_9 + 0,062 * X_{12} - 0,040 * X_{13} + 0,001 * X_{15}$$

Hair (2009, p. 38) deixa um alerta para os pesquisadores “que sempre deve garantir que haja observações suficientes por parâmetro estimado, para evitar superajustamento da amostra. Contudo, igualmente importantes são os esforços para validar os resultados. Separar a amostra para estimar o modelo, e usar uma subamostra para estimar a precisão”.

Sendo assim, obteve-se outra amostra, ou seja, não pertencente à amostra utilizada para análise da criação do **modelo de previsão de insolvência Aranha & Gondrige**. Foram selecionados grupos, sendo um com 10 companhias insolventes ou que apresentaram anomalias como prejuízos e Passivo a Descoberto e outro com 10 companhias solventes, totalizando uma amostra teste de 20 empresas.

Segundo Hair (2009, p. 39) “o objetivo não é determinar o melhor ajuste apenas para os dados da amostra, mas desenvolver um modelo que melhor descreva a população como um todo”.

Sendo assim, a amostra teste, em termos de comparação entre os dois grupos “empresas insolventes e empresas solventes”, não seguiu os critérios adotados na amostra de análise usada na criação da função. Sua separação foi aleatória, não levando em consideração os critérios de mesmo segmento, subsetor e tamanho do Ativo Total.

Tabela 18: Relação de Empresas Solventes, em Recuperação Judicial, com Prejuízos Sistemáticos e com Passivo a Descoberto em 2019

Empresa Solventes – Agrupamento “1”	Empresa Insolventes – Agrupamento “0”
Banco Pan	Mundial
Ambev S/A	Taurus Armas
Intelbrás	Estrela
Ampla Energ	Mendes Jr
Duratex	Cor Ribeiro
Embraer	IGB S/A
Pague Menos	Hotéis Othon
Klabin S/A	Sansuy
Lojas Renner	Getninjas
All Norte	Proman

Fonte: o Autor, 2021

A seguir, têm-se os índices das 20 companhias que compõem a amostra para validação do modelo, conforme tabela 19. Foram escolhidas aleatoriamente as empresas, perfazendo um grupo de 10 em situação de falência “empresas 0”, em recuperação judicial, que apresentam sistematicamente prejuízos e possuem passivo a descoberto e outro grupo com 10 empresas solventes “empresas 1”.

De posse dos índices das empresas, o próximo passo foi criar uma coluna com o Escore Discriminante, e submetê-los ao **modelo de previsão de insolvência Aranha & Gondrige**.

A próxima etapa foi a validação da função discriminante quanto ao seu potencial de classificação, ou seja, quantos por cento a função consegue classificar as empresas corretamente em seus respectivos grupos.

Tabela 19: Variáveis Empresas, Escore Discriminante e Classificação Excel[®]

Empresas	X₁	X₉	X₁₂	X₁₃	X₁₅	Escore Discriminante	Classificação Excel[®]
0	0,6	14,9	-1,9	0,3	-785,8	-1,05	0
0	0,4	32,8	-2,3	0,8	-393,3	-1,14	0
0	0,2	-63,7	0,0	0,1	-128,0	-0,69	0
0	0,1	73,8	0,0	0,0	-108,6	-1,27	0
0	0,7	100,0	-0,3	0,1	-378,6	-0,58	0
0	0,2	79,4	0,0	0,0	-130,6	-1,12	0
0	0,2	65,1	-0,2	0,2	-240,5	-1,24	0
0	0,1	3,1	-0,3	1,2	-122,2	-1,11	0
0	0,4	91,9	-5,1	4,2	-221,8	-1,30	0
0	0,1	67,0	-6,1	0,3	-2.007,8	-3,42	0
1	1,1	53,1	1,7	0,2	574,4	1,35	1
1	0,5	47,2	0,4	0,3	62,1	-0,25	0
1	1,5	34,1	2,3	1,1	120,5	1,51	1
1	1,1	16,5	1,6	0,6	188,7	1,05	1
1	0,8	21,1	0,8	0,5	62,5	0,38	1
1	1,2	8,5	0,4	0,2	155,5	1,07	1

1	0,7	31,4	6,3	1,3	369,3	0,73	1
1	0,7	31,7	1,7	0,3	462,7	0,52	1
1	0,9	57,0	1,7	0,8	101,1	0,44	1
1	0,9	41,7	1,1	0,3	238,1	0,63	1

Fonte: o Autor, 2021

A Função Discriminante Aranha & Gondrige, quando analisou a amostra teste composta por 20 companhias escolhidas aleatoriamente, obteve um resultado excelente, classificando corretamente 95% das empresas da amostra teste.

Segue demonstração do cálculo de classificação das empresas em porcentagem:

Empresas “0” = quantidade de companhias classificadas corretamente dividida pela quantidade de companhia que compõe o grupo de empresas “0” e multiplicado por 100 para obter o resultado em percentual, ou seja, $(10/10) * 100 = 100\%$.

Empresas “1” = quantidade de companhias classificadas corretamente dividida pela quantidade de companhia que compõe o grupo de empresas “1” e multiplicado por 100 para obter o resultado em percentual, ou seja, $(09/10) * 100 = 90\%$.

Somam-se as resultantes das duas empresas e divide-se por 2 para que possamos chegar ao resultado, logo, temos nessa amostra, 95% de classificação correta.

4.2 Comparação com os Modelos Existentes

Para comprovação do poder discriminatório do **Modelo de Previsão de Insolvência Aranha & Gondrige**, optou-se em compará-lo com outros modelos existentes e já discutidos neste trabalho, como o modelo de Kanitz, por ser o pioneiro no uso de análise discriminante no Brasil; o modelo de Elizabetsky (1976), com o estudo matemático para obtenção de crédito bancário com uma amostra no segmento de confecções; o modelo de Matias (1978), aplicado a empresas de diversos ramos de atividades; o modelo de Altman (1979), com estudo de empresas brasileiras, obtendo com o modelo duas funções Z_1 e Z_2 .

Todos os modelos escolhidos foram submetidos à mesma amostra utilizada no desenvolvimento do modelo de previsão de insolvência Aranha & Gondrige, embora cada função tenha sido submetida à análise com suas respectivas variáveis independentes.

A seguir, o estudo aplicando o Termômetro de Insolvência de Kanitz, com a seguinte função discriminante:

$$FI = 0,05X_1 + 1,65X_2 + 3,55X_3 - 1,06X_4 + 0,33X_5$$

De acordo com o termômetro de insolvência desenvolvido por Kanitz, as empresas que se classificam entre 0 e 7, estão na faixa de solvência, enquanto outras classificadas entre 0 e -3, estão na zona de sombreamento, que é considerado região penumbra, ou seja, são consideradas indefinidas e, as empresas que estão entre -3 e -7, são consideradas insolventes.

Tabela 20: Variáveis Independentes na Função de Kanitz

Empresas	X ₁	X ₂	X ₃	X ₄	X ₅	Escore Discriminante	Classificação Excel [®]
0	-0,01	0,07	0,01	0,04	-108,91	-35,85	0
0	0,18	0,01	0,02	0,02	-521,49	-172,00	0
0	-0,06	0,63	1,17	1,26	-4895,20	-1611,56	0
0	0,08	0,04	0,00	0,00	-103,73	-34,16	0
0	0,09	0,00	1,31	1,31	-100,07	-29,75	0
0	0,19	0,20	0,01	0,02	-156,98	-51,44	0
0	0,57	0,46	0,05	0,06	-992,25	-326,55	0
0	1,64	0,03	0,00	0,00	-358,42	-118,13	0
0	4,48	0,52	0,30	0,68	-13810,88	-4556,15	0
0	-0,03	0,32	1,69	1,83	-173,13	-52,55	0
0	0,29	0,27	0,28	0,29	-210,49	-68,32	0
0	-0,04	0,05	44,67	44,67	-167,96	55,88	1
0	2,09	0,44	0,56	0,68	-867,09	-284,04	0
0	0,00	0,06	0,02	0,02	-112,04	-36,83	0
0	0,05	0,33	0,69	0,78	-159,67	-50,53	0
0	-6,61	0,29	0,24	0,48	-7368,97	-2431,27	0
0	0,19	0,16	0,14	0,25	-183,75	-60,15	0
0	0,26	0,91	0,05	0,19	-3496,21	-1152,28	0
0	0,12	0,03	0,00	0,00	-103,64	-34,13	0
0	0,08	0,44	0,46	0,49	-190,31	-60,98	0
0	0,14	0,41	0,45	0,57	-326,86	-106,19	0
0	0,17	0,60	0,38	0,64	-459,04	-149,82	0
0	0,02	0,27	1,50	2,02	-203,79	-63,62	0
0	0,05	0,39	1,28	1,95	-258,50	-82,17	0
0	0,02	0,11	0,01	0,01	-112,51	-36,92	0
0	0,08	0,31	0,02	0,03	-161,27	-52,66	0
0	-0,07	0,14	0,07	0,19	-163,13	-53,56	0
0	-0,01	0,02	0,01	0,01	-102,58	-33,78	0
0	0,01	0,01	0,00	0,00	-101,29	-33,40	0
0	20,81	0,73	0,83	1,51	4934,00	1631,81	1
1	0,65	0,99	1,12	1,20	396,62	135,26	1
1	0,10	0,35	1,21	1,32	183,13	63,89	1
1	0,04	0,63	0,62	0,78	452,05	151,59	1
1	0,35	0,68	0,82	0,96	3683,45	1218,58	1
1	0,20	1,06	1,25	1,81	72,44	28,18	1
1	0,12	1,24	1,20	1,69	146,03	52,71	1
1	0,08	0,81	0,53	0,97	95,46	33,71	1
1	0,14	1,30	1,15	2,30	167,66	59,11	1

1	0,20	1,14	5,86	6,30	76,54	41,29	1
1	0,13	1,07	1,15	1,15	36,69	16,73	1
1	0,04	0,90	1,02	1,41	397,33	134,72	1
1	0,08	2,31	2,37	2,37	42,35	23,68	1
1	0,16	1,41	2,03	2,07	109,02	43,34	1
1	0,26	1,13	1,76	1,76	286,08	100,65	1
1	0,51	0,73	0,68	1,19	360,25	121,28	1
1	0,17	1,03	1,16	1,69	181,38	63,90	1
1	0,09	1,04	1,83	2,12	64,42	27,24	1
1	0,15	1,03	2,42	2,82	155,24	58,52	1
1	0,12	0,89	1,79	2,24	89,33	34,93	1
1	0,06	0,44	0,79	0,79	192,98	66,37	1
1	0,14	0,25	0,42	0,52	282,05	94,42	1
1	0,25	1,10	1,01	1,41	191,25	67,04	1
1	0,66	2,14	1,80	1,80	65,16	29,54	1
1	2,69	0,56	1,04	1,99	337,42	113,98	1
1	0,05	2,52	2,18	3,03	24,58	16,81	1
1	0,15	3,67	2,72	3,71	27,16	20,75	1
1	0,05	2,61	4,10	6,20	24,13	20,25	1
1	0,03	1,05	0,82	1,67	45,67	17,93	1
1	0,04	1,40	0,76	1,36	107,14	38,92	1
1	0,59	1,19	1,22	1,37	154,96	56,00	1

Fonte: o Autor, 2021

Com o intuito de verificar o poder discriminatório da função de Kanitz, classificou corretamente 93,33% das empresas “0” (insolventes) e, no grupo de empresas “1” (solventes), o índice foi de 100,00%. Sendo assim, a função discriminante de Kanitz teve um poder de classificação com os dados da amostra de 96,67%.

Da mesma forma, os dados foram analisados pela função discriminante de Elizabetsky, em que, se o ponto de corte da função for menor que 0,05, será insolvente e maior que 0,05, será solvente.

$$Z = 1,93204 * X_{32} - 0,20583 * X_{33} + 1,020377 * X_{35} + 1,33354 * X_{36} - 1,12899 * X_{37}$$

Tabela 21: Variáveis Independentes na Função de Elizabetsky

Empresas	X ₃₂	X ₃₃	X ₃₅	X ₃₆	X ₃₇	Escore Discriminante	Classificação Excel®
0	0,00	0,00	0,00	0,38	10,53	-11,39	0
0	0,00	0,00	0,00	0,00	0,13	-0,15	0
0	0,00	0,00	0,14	0,13	0,25	0,03	0
0	0,00	0,00	0,00	0,00	0,66	-0,75	0
0	0,00	0,00	0,04	0,03	0,34	-0,31	0
0	0,00	0,00	0,00	0,00	0,03	-0,03	0
0	0,00	0,00	0,17	0,01	1,07	-1,02	0
0	0,00	0,00	0,00	0,00	0,00	0,00	0
0	0,00	0,00	0,00	0,00	2,05	-2,31	0
0	0,00	0,00	0,00	0,01	0,04	-0,03	0
0	0,00	0,00	0,39	0,07	1,84	-1,60	0
0	0,00	0,00	0,38	0,21	0,32	0,31	1
0	0,00	0,00	0,62	0,00	8,97	-9,50	0
0	0,00	0,00	0,04	0,02	2,24	-2,46	0
0	0,00	0,00	0,09	0,20	1,74	-1,60	0
0	0,00	0,00	0,00	0,00	0,80	-0,89	0
0	0,00	0,00	0,02	0,01	0,60	-0,65	0
0	0,00	0,00	0,00	0,00	1,32	-1,49	0
0	0,00	0,00	0,11	0,07	0,56	-0,43	0
0	0,00	0,00	0,00	0,00	2,94	-3,32	0
0	0,00	0,00	0,06	0,04	0,49	-0,43	0
0	0,00	0,00	0,12	0,15	0,60	-0,35	0
0	0,00	0,00	0,09	0,10	0,91	-0,80	0
0	0,00	0,00	0,27	0,08	0,73	-0,43	0
0	0,00	0,00	0,11	0,20	0,53	-0,23	0
0	0,00	0,00	0,06	0,06	0,42	-0,33	0
0	0,00	0,00	0,25	0,29	1,11	-0,62	0
0	0,00	0,00	0,04	0,00	3,97	-4,45	0
0	0,00	0,00	0,00	0,00	75,73	-85,49	0
0	0,00	0,00	0,11	0,22	0,32	0,04	0
1	0,00	0,00	0,29	0,04	0,50	-0,22	0
1	0,00	0,00	0,06	0,01	0,11	-0,05	0
1	0,00	0,00	0,00	0,14	0,32	-0,18	0
1	0,00	0,00	0,16	0,13	0,15	0,16	1
1	0,00	0,00	0,14	0,13	0,23	0,06	1
1	0,00	0,00	0,14	0,06	0,40	-0,23	0
1	0,00	0,00	0,04	0,03	0,22	-0,17	0
1	0,00	0,00	0,00	0,19	0,39	-0,19	0
1	0,00	0,00	0,14	0,07	0,48	-0,30	0
1	0,00	0,00	0,02	0,00	0,11	-0,09	0
1	0,00	0,00	0,10	0,00	0,13	-0,04	0
1	0,00	0,00	0,07	0,00	0,19	-0,14	0
1	0,00	0,00	0,16	0,00	0,30	-0,17	0
1	0,00	0,00	0,00	0,02	0,24	-0,24	0

1	0,00	0,00	0,00	0,13	0,34	-0,20	0
1	0,00	0,00	0,13	0,20	0,21	0,16	1
1	0,00	0,00	0,18	0,16	0,07	0,31	1
1	0,00	0,00	0,10	0,16	0,19	0,10	1
1	0,00	0,00	0,20	0,20	0,33	0,09	1
1	0,00	0,00	0,06	0,19	0,17	0,13	1
1	0,00	0,00	0,03	0,03	0,07	-0,01	0
1	0,00	0,00	0,00	0,00	0,21	-0,24	0
1	0,00	0,00	0,12	0,21	0,42	-0,07	0
1	0,00	0,00	0,30	0,20	0,39	0,14	1
1	0,00	0,00	0,10	0,05	0,17	-0,03	0
1	0,00	0,00	0,04	0,08	0,19	-0,07	0
1	0,00	0,00	0,09	0,06	0,13	0,03	0
1	0,00	0,00	0,12	0,12	0,31	-0,06	0
1	0,00	0,00	0,29	0,00	0,32	-0,07	0
1	0,00	0,00	0,24	0,18	0,18	0,28	1

Fonte: o Autor, 2021

Ao submeter à análise as variáveis independentes da função discriminante de Elizabetsky, obteve-se o poder classificatório para as empresas “0” de 96,67% e, para as empresas “1”, houve classificação correta apenas de 30% das companhias.

De certo modo, o modelo atingiu 63,33% de classificação correta da amostra.

A próxima função analisada foi a de Matias e o ponto crítico desse modelo é zero:

$$Z = 23,792X_1 - 8,260X_2 - 8,868X_3 - 0,764X_4 + 0,535X_5 + 9,912X_6$$

Tabela 22: Amostra de Variáveis Independentes na Função de Matias

Empresas	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	Escore Discriminante	Classificação Excel [®]
0	-11,22	0,78	0,74	0,04	0,00	0,00	-280,03	0
0	-0,24	0,00	0,00	0,02	0,00	0,00	-5,66	0
0	-0,02	0,39	0,07	1,26	0,00	0,00	-5,28	0
0	-26,78	0,00	0,02	0,00	0,00	0,00	-637,37	0
0	-1362,32	0,00	0,00	1,31	0,00	0,00	-32413,34	0
0	-1,75	8,78	0,01	0,02	0,00	0,00	-114,40	0
0	-0,11	3,50	0,01	0,06	0,00	0,00	-31,71	0
0	-0,39	0,12	0,01	0,00	0,00	0,00	-10,36	0
0	-0,01	0,27	0,09	0,68	0,00	0,00	-3,72	0
0	-1,37	0,48	0,01	1,83	0,00	0,00	-38,00	0
0	-0,91	0,04	0,15	0,29	0,00	0,00	-23,40	0
0	-1,47	0,00	0,00	44,67	0,00	0,00	-69,14	0
0	-0,13	0,00	0,16	0,68	0,00	0,00	-5,05	0
0	-8,31	0,00	0,02	0,02	0,00	0,00	-197,79	0
0	-1,68	0,00	0,01	0,78	0,00	0,00	-40,53	0
0	-0,01	0,00	0,03	0,48	0,00	0,00	-0,97	0

0	-1,19	1,67	0,15	0,25	0,00	0,00	-43,67	0
0	-0,03	0,00	0,00	0,19	0,00	0,00	-0,87	0
0	-27,48	0,00	0,33	0,00	0,00	0,00	-656,74	0
0	-1,11	0,00	0,01	0,49	0,00	0,00	-26,77	0
0	-0,44	0,97	0,17	0,57	0,00	0,00	-20,41	0
0	-0,28	0,24	0,27	0,64	-0,02	0,00	-11,51	0
0	-0,96	0,07	0,07	2,02	0,00	0,00	-25,70	0
0	-0,63	0,03	0,12	1,95	0,00	0,00	-17,82	0
0	-7,99	4,79	1,34	0,01	0,00	0,00	-241,60	0
0	-1,63	7,66	0,37	0,03	0,00	0,00	-105,44	0
0	-1,58	0,72	0,34	0,19	0,00	0,00	-46,80	0
0	-38,79	0,00	0,01	0,01	0,00	0,00	-922,98	0
0	-77,69	0,00	0,00	0,00	-30,74	0,00	-1864,84	0
0	0,02	0,21	0,15	1,51	0,00	0,00	-3,75	0
1	0,20	0,00	0,11	1,20	0,00	0,00	2,90	1
1	0,35	0,11	0,01	1,32	0,00	0,00	6,33	1
1	0,18	0,22	0,15	0,78	0,00	0,00	0,57	1
1	0,03	0,43	0,05	0,96	0,00	0,00	-4,13	0
1	0,58	0,22	0,05	1,81	0,00	0,00	10,15	1
1	0,41	0,00	0,29	1,69	0,00	0,00	5,80	1
1	0,51	0,00	0,29	0,97	0,00	0,00	8,85	1
1	0,37	0,01	0,02	2,30	0,00	0,00	6,86	1
1	0,57	0,00	0,00	6,30	0,00	0,00	8,63	1
1	0,73	0,04	0,00	1,15	0,00	0,00	16,19	1
1	0,70	0,00	0,01	2,37	0,00	0,00	14,83	1
1	0,20	0,16	0,07	1,41	0,00	0,00	1,70	1
1	0,48	0,04	0,01	2,07	0,00	0,00	9,43	1
1	0,26	0,08	0,06	1,76	0,00	0,00	3,65	1
1	0,22	0,00	0,15	1,19	0,00	0,00	2,97	1
1	0,36	0,22	0,09	1,69	0,00	0,00	4,58	1
1	0,61	0,13	0,05	2,12	0,00	0,00	11,31	1
1	0,39	0,16	0,05	2,82	0,00	0,00	5,42	1
1	0,53	0,04	0,06	2,24	0,00	0,00	9,96	1
1	0,34	0,44	0,07	0,79	0,00	0,00	3,24	1
1	0,26	1,06	0,03	0,52	0,00	0,00	-3,16	0
1	0,34	0,34	0,09	1,41	0,00	0,00	3,47	1
1	0,61	0,00	0,01	1,80	0,97	0,00	13,48	1
1	0,23	0,06	0,11	1,99	0,00	0,00	2,41	1
1	0,80	0,01	0,10	3,03	0,00	0,00	15,82	1
1	0,81	0,00	0,02	6,20	0,00	0,00	14,21	1
1	0,69	0,25	0,06	1,67	0,00	0,00	12,45	1
1	0,48	0,49	0,07	1,36	0,00	0,00	5,79	1
1	0,79	0,00	0,10	3,71	0,00	0,00	14,96	1
1	0,39	0,00	0,28	1,37	0,00	0,00	5,82	1

Fonte: o Autor, 2021

O poder classificatório para as empresas “0” foi de 100% das companhias classificadas corretamente; no outro grupo, pertencente às empresas “1”, o índice foi de 93,33% de classificação correta. Sendo assim, na análise da função de Matias, obteve-se o poder discriminatório de 96,67%.

Por fim, o resultado do estudo de comparação dos modelos desenvolvidos por Altman com as funções discriminante Z_1 e Z_2 :

$$Z_1 = -1,44 + 4,03X_2 + 2,25X_3 + 0,14X_4 + 0,42X_5$$

$$Z_2 = -1,84 - 0,51X_1 + 6,32X_3 + 0,71X_4 + 0,52X_5$$

Em ambos os modelos, Z_1 e Z_2 , Altman atribuiu o ponto crítico em zero, ou seja, $Z > 0$ empresas solventes e $Z < 0$ empresas insolventes, conforme Tabela 23.

Tabela 23: Variáveis Empresas Modelo Altman Função Z_1 e Z_2

E m p r e s a s	X_1	X_2	X_3	X_4	X_5	Score Discrimi nante Z_1	Clas sifi caç ão	Escore Discri minant e Z_2	Clas sifi caç ão
							Exc el [®] Z_1		Exc el [®] Z_2
0	-10,07	-46,02	-0,30	-0,92	0,00	-187,71	0	0,75	1
0	-0,13	-1,74	-0,08	-0,19	0,00	-8,66	0	-2,43	0
0	0,25	-2,40	0,11	-0,49	0,00	-10,92	0	-1,61	0
0	0,21	-20306,91	-129,17	-1,00	0,00	-82129,04	0	-819,01	0
0	0,09	-0,05	0,07	-0,02	0,00	-1,48	0	-1,45	0
0	-0,03	-64,72	-1,97	-0,96	0,00	-266,82	0	-14,95	0
0	-0,76	-1,62	-0,13	-0,48	0,00	-8,35	0	-2,64	0
0	0,03	-3,79	0,06	-0,60	0,00	-16,67	0	-1,91	0
0	-2,04	-64,93	-3,36	-0,96	0,00	-270,81	0	-22,71	0
0	-0,03	-0,08	-0,02	-0,03	0,00	-1,80	0	-1,95	0
0	-0,94	-2,33	-0,08	-0,53	0,00	-11,06	0	-2,24	0
0	0,30	-1,57	0,08	-0,39	0,00	-7,64	0	-1,78	0
0	-8,85	-18,15	-0,02	-0,89	0,00	-74,75	0	1,89	1
0	-2,17	-3,40	-0,03	-0,62	0,00	-15,32	0	-1,37	0
0	-1,42	-3,28	0,13	-0,61	0,00	-14,45	0	-0,70	0
0	-0,78	-5,76	-0,20	-0,64	0,00	-25,18	0	-3,15	0
0	-0,57	-0,76	-0,07	-0,10	0,00	-4,69	0	-2,08	0
0	-1,31	-7,11	-0,56	-0,28	0,00	-31,38	0	-4,93	0
0	-0,18	-0,13	-0,30	-0,12	0,00	-2,66	0	-3,72	0
0	-2,89	-23,05	0,18	-0,89	0,00	-94,05	0	0,13	1
0	-0,11	-8,36	0,00	-0,63	0,00	-35,24	0	-2,26	0
0	-0,31	-0,22	0,16	-0,01	0,00	-1,99	0	-0,69	0

0	-0,68	-2,77	-0,08	-0,54	0,00	-12,84	0	-2,37	0
0	-0,31	-2,39	0,10	-0,31	0,00	-10,88	0	-1,27	0
0	-0,17	-0,83	0,04	-0,01	0,00	-4,71	0	-1,51	0
0	0,35	-3,08	0,08	-0,58	0,00	-13,76	0	-1,95	0
0	-0,40	-1,85	0,06	-0,22	0,00	-8,81	0	-1,40	0
0	-3,93	-79,89	0,07	-0,97	0,00	-323,36	0	-0,06	0
0	-75,58	-157,94	-0,78	-0,99	0,00	-639,84	0	31,07	1
0	0,16	-0,36	-0,10	0,02	0,00	-3,09	0	-2,52	0
1	0,10	0,30	0,22	0,25	0,00	0,29	1	-0,35	0
1	0,04	0,35	0,08	0,55	0,00	0,23	1	-0,99	0
1	-0,01	0,51	0,07	1,05	0,00	0,92	1	-0,67	0
1	0,31	0,80	0,05	4,07	0,00	2,49	1	1,23	1
1	0,19	0,58	0,14	1,38	0,00	1,41	1	-0,07	0
1	-0,09	0,09	0,07	0,22	0,00	-0,88	0	-1,16	0
1	-0,01	-0,11	0,06	0,03	0,00	-1,73	0	-1,44	0
1	0,27	0,41	0,07	0,68	0,00	0,45	1	-1,05	0
1	0,18	0,39	0,08	0,65	0,00	0,42	1	-0,94	0
1	0,11	0,48	0,08	0,92	0,00	0,81	1	-0,71	0
1	0,10	0,26	0,10	0,35	0,00	-0,11	0	-0,99	0
1	0,25	0,70	0,05	2,36	0,00	1,83	1	0,01	1
1	-0,06	0,34	0,05	0,52	0,00	0,12	1	-1,13	0
1	-0,12	0,26	0,07	0,35	0,00	-0,17	0	-1,06	0
1	0,14	0,34	0,05	0,52	0,00	0,14	1	-1,20	0
1	0,21	0,03	0,35	0,30	0,00	-0,50	0	0,50	1
1	0,39	0,81	0,01	4,14	0,00	2,40	1	0,94	1
1	0,13	0,71	0,03	2,19	0,00	1,80	1	-0,18	0
1	0,12	0,48	0,06	0,93	0,00	0,77	1	-0,87	0
1	0,22	0,37	0,05	0,60	0,00	0,26	1	-1,20	0
1	0,36	0,57	0,11	1,31	0,00	1,27	1	-0,40	0
1	0,03	0,73	0,10	2,73	0,00	2,11	1	0,71	1
1	0,08	0,22	0,17	0,28	0,00	-0,15	0	-0,62	0
1	0,27	0,36	0,11	0,55	0,00	0,31	1	-0,92	0
1	0,19	0,61	0,05	1,55	0,00	1,35	1	-0,49	0
1	0,35	0,39	0,08	0,64	0,00	0,41	1	-1,05	0
1	0,16	0,53	0,08	1,12	0,00	1,03	1	-0,61	0
1	0,13	0,20	0,03	0,25	0,00	-0,52	0	-1,52	0
1	0,26	0,30	0,23	1,53	0,00	0,49	1	0,56	1
1	0,49	0,79	0,10	3,68	0,00	2,46	1	1,14	1

Fonte: o Autor, 2021

Dessa forma, detalham-se os cálculos e o poder de classificação obtidos nas Funções Z_1 e Z_2 de Altman, quando submetidos a teste com a amostra utilizada na função Aranha & Gondrige. Para a Função Z_1 , com um grupo de 30 empresas “0”, classificou corretamente as 30 empresas que correspondem a 100%, por outro lado, no outro grupo, empresas “1” classificou corretamente 76,67% correspondentes a 23 empresas.

Portanto, a Função Z_1 de Altman teve o poder classificatório de 88,33%, quando submetida a teste na amostra utilizada em nossa pesquisa; do mesmo modo, temos a Função Z_2 , que também foi desenvolvida por Altman, para o grupo de empresas “0”, classificou corretamente 26 das 30 empresas e atingiu 86,67%. No entanto, a classificação correta para o grupo de empresas “1” foi de 23,33%, que corresponde a 07 empresas do seu respectivo grupo de 30. Sendo assim, a função Z_2 classificou corretamente 55% das companhias pertencente à amostra a que foi submetida.

Por fim, temos demonstrado na Tabela 24 o ranking dos modelos comparados e o percentual do poder de classificação de cada modelo quando submetido à amostra utilizada em nosso estudo, respeitando as variáveis independentes de cada modelo:

Tabela 24: Classificação dos Modelos

Kanitz	96,67 %
Matias	96,67 %
Aranha & Gondrige	93,33 %
Altman Z_1	88,33 %
Elizabetsky	63,33 %
Altman Z_2	55,00 %

Fonte: o Autor, 2021

Observando os resultados da tabela 24, tem-se o poder de classificação dos modelos submetidos à análise e as respectivas comparações. Nota-se que o **Modelo de Previsão de Insolvência Aranha & Gondrige** apresentou elevado poder de discriminação a nível dos de Kanitz, e Matias, portanto, trata-se de um modelo com elevado poder de discriminação entre companhias solventes e insolventes.

5. CONCLUSÃO

O objetivo da pesquisa foi desenvolver um modelo de Análise Discriminante para previsão de insolvência. Ressalta-se que o estudo, ao se dedicar a propor um modelo de previsão de insolvência, baseia-se na teoria das finanças; logo, reconhece-se que essa teoria e as reflexões em torno dos subtemas, são determinantes para que novas considerações e análises da motivação sejam feitas.

Por conseguinte, após discutir os modelos existentes que fazem uso da análise discriminante, bem como diante da necessidade de um modelo atual, tendo em vista as várias mudanças na conjuntura econômica do País, desde os últimos modelos, o resultado obtido, testado e validado, foi um modelo de previsão de insolvência com a aplicação da análise discriminante.

Os resultados alcançados pelo **Modelo de Previsão de Insolvência Aranha & Gondrige** apresentam um poder explicativo de 90%, ou seja, há um elevado poder de separar empresas insolventes das solventes. Quando submetido a teste de validação, o índice de acerto foi de 95%. Ao compará-lo com os modelos existentes, obteve sucesso de 93,33%, superando os modelos de Altman e de Elizabetsky, numa faixa próxima ao de Kanitz e Matias, que obtiveram ambos 96,67% de classificação correta.

Destarte, dada a diversidade dos segmentos da economia e do campo em que atuam, é possível utilizar-se do **Modelo de Previsão de Insolvência Aranha & Gondrige**, cabendo aos gestores a função de acompanhar a situação financeira da empresa; aos analistas de créditos, a análise dos prováveis tomadores de crédito no sentido de avaliar as condições econômico-financeiras dessas companhias; aos analistas de investimentos, recomendar ou não aos seus clientes em potencial o possível investimento; aos gerentes financeiros, analisar os possíveis fornecedores de matéria prima e clientes, no sentido de vender ou não a prazo. Podendo ainda, por meio de estratégias de análise, definir, dentre os modelos discutidos, o que melhor se ajusta ao problema em questão para a tomada de decisão.

Portanto, a pesquisa atingiu o objetivo proposto e, de futuro, espera-se que o estudo contribua para a discussão acerca dos modelos proporcionando resultados que servirão de base para próximas pesquisas. Com o propósito de aferir ainda mais a capacidade de prever insolvência, a função discriminante desenvolvida deverá ser submetida a testes de comparação com os modelos existentes, como os de Altman, Elizabetsky, Kanitz, Matias Borges e Pereira, dentre outros, utilizando-se para esse fim de amostra mais robusta.

6. REFERÊNCIAS

ANDRADE, Jefferson Pereira, LUCENA, Wenner Glaucio Lopes. **Análise de Desempenho dos Modelos de Previsão de Insolvência e a Implementação das Normas Internacionais de Contabilidade**. Rev. Ciênc. Admin., Fortaleza, v. 24, n.2, p. 1-14. Maio./Ago. 2018.

ALTMAN, Edward I. **Financial Ratios, Discriminant Analysis And The Prediction of Corporate Bankruptcy**. The Journal of Finance, Vol. 23, No. 4. (Sep., 1968), pp. 589-609.

_____; BAIDYA, Tara K. N.; DIAS, Luiz Manoel Ribeiro. **Previsão de Problemas Financeiros em Empresas – 1978**. Revista Administração de Empresas – RAE - Rio de Janeiro – RJ. jan./mar.1979.

ARANHA, José A. Moura; LINS FILHO, Oduvaldo da Silva. **Modelos de Previsão de Insolvências: O Termômetro de Kanitz na Avaliação de Empresas do Setor de Aviação Comercial**. In: V Jornada Científica do Centro-Oeste de Economia e Administração, 5., 2005, Campo Grande. MS. Brasil. Anais...Campo Grande: UFMS, 2005.

_____; **Análise Financeira e Índices Padrão Para o Setor Elétrico Brasileiro**. Guia prático para construção de índices-padrão. Novas Edições Acadêmicas, 2015.

ASSAF NETO, Alexandre. **Estrutura e Análise de Balanços: um enfoque econômico-financeiro**. 12 ed. São Paulo: Atlas, 2020.

Bolsa, Brasil, Balcão – B3. **Dados da Amostra**. Disponível em: http://www.b3.com.br/pt_br/. Acessado em 30 Jun. 2021.

CASTRO JUNIOR, Francisco Henrique Figueiredo de. **Previsão de Insolvência de Empresas Brasileiras Usando Análise Discriminante, Regressão Logística e Redes Neurais**. São Paulo, FEA/USP, 2003. Dissertação (Mestrado), Faculdade de Economia, Administração e Contabilidade da USP II.

COMISSÃO DE VALORES MOBILIÁRIOS – CVM. **Dados da Amostra**. Disponível em: <http://sistemas.cvm.gov.br/>. Acessado em 17 Jun. 2021.

CORRAR, Luiz J.; PAULO, Edilson; e DIAS FILHO, José Maria. **Análise Multivariada**. São Paulo: Atlas, 2014.

CRESWELL, John W. Projeto de Pesquisa. **Métodos Qualitativos, Quantitativos e Misto** – 2 ed. – Porto Alegre, 2007.

ECONOMÁTICA: **Banco de Dados**. Disponível em: <http://www.economatica.com>. Acessado em 10 Mai. 2021.

FIGUEIREDO, Helena Maria Ferreira. **O Problema da Recuperação de Empresas Em Portugal: Análise Crítica**. Coimbra, Portugal, 2018. Dissertação (Mestrado), Coimbra Business School, Instituto Superior de Contabilidade e Administração de Coimbra.

GIL, A. C. **Como Elaborar Projetos de Pesquisa**. 6. ed. São Paulo: Atlas, 2017.

GIRÃO, António Pedro Panão. **Previsão de Insolvência nas PME: O Setor das Empresas Comercializadoras de Materiais de Construção**. Portugal - Coimbra, 2015. Dissertação (Mestrado), Faculdade de Economia da Universidade de Coimbra.

GUJARATI, Damodar N.; DAWN, C. Porter. **Econometria Básica**. Porto alegre 2011. Tradução Denise Durante, Mônica Rosemberg; Maria Lúcia G. L. Rosa. Revisão Técnica Claudio D. Shikida; Ari Francisco de Araújo Júnior; Márcio Antônio Salvato, – 5.ed.

HAIR, Joseph F.; ANDERSON, Rolph E.; TATHAM, Ronald L.; BLACK, William C. **Análise Multivariada de Dados**. Porto Alegre: Bookman, 2009. Tradução da 6 edição americana por Adonai Schlup Sant´Anna e Anselmo Chaves Neto.

IUDÍCIBUS, Sérgio de. **Contabilidade Introdutória**. 12. ed. São Paulo: Atlas, 2019. Equipe de professores da FEA/USP.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Censo Demográfico 2010**. Disponível em <https://www.ibge.gov.br>. Acesso em 15 dez. 2018.

IBM **SPSS** Statistics Versão: 28.0.0.0 (190).

JANOT, Marcio Magalhães. **Modelos de Previsão de Insolvência Bancária no Brasil**. Brasília, 2001. Trabalhos para Discussão nº 13.

KANITZ, Stephen Charles. **Como Prever Falências de Empresas**. Artigo publicado na Revista Exame, Dez. de 1974.

KASSAI, JOSÉ Roberto; KASSAI, Silvia Pereira de Castro. **Desvendando o Termômetro de Insolvência de Kanitz**. Anais. Ribeirão Preto: FEA-USP, 1999.

LOTT, Vinicius Freitas. **Fatores Determinantes do Endividamento e Predição de Insolvência: Um Estudo Comparativo Entre Brasil e Estados Unidos**. Belo Horizonte, MG, 2020. Dissertação (Mestrado), Universidade Federal de Minas Gerais, Centro de Pós-Graduação e Pesquisa em Administração.

MARCONI, Marina de Andrade; LAKATOS, Eva Maria. **Fundamentos de Metodologia Científica**. 7. ed. São Paulo: Atlas, 2017.

_____; _____. **Técnicas de Pesquisa**. 11. ed. São Paulo: Saraiva, 2015.

MAROCO, João. **Análise Estatística: Com a Utilização do SPSS**. Lisboa Sílabo. 2003.

MARQUES, Graciele Turra; MILANI, Bruno. **Influência da Liquidez Sobre a Rentabilidade: Análise das Empresas Listadas no INDX no Período de 2005 A 2013**. Revista Do CEPE. Santa Cruz do Sul, Instituto Federal de Educação, Ciência e Tecnologia Farroupilha – IFF – Santa Maria. n. 45, p. 143-159, jan./jun. 2017.

MATARAZZO, D. C. **Análise Financeira de Balanços: abordagem gerencial**. 7. ed. São Paulo: Atlas, 2017.

MATIAS, Alberto Borges. **Indicadores Contábeis e Financeiros de Previsão de Insolvência: A Experiência da Pequena e Média Empresa**. 1976. Tese (Livre-Docência) – Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, São Paulo, 1976.

MELLO, Gilmar Ribeiro de; SLOMSKI, Valmor. **A Situação Financeira dos Estados Brasileiros: Uma Proposta Utilizando Análise Discriminante**. Revista de Contabilidade e Organizações – FEARP/USP, v. 1, n. 1, p.73 – 86 set./dez., 2007.

MINGOTI, Sueli A. **Análise de Dados Através de Métodos de Estatística Multivariada: Uma Abordagem Aplicada**. 2ª impressão. Belo Horizonte: ed. UFMG, 2013.

NASCIMENTO, Sabrina do; PEREIRA, Alexandre Matos; HOELTGEBAUM Marianne. **Aplicação dos Modelos de Previsão de Insolvências nas Grandes Empresas Aéreas Brasileiras**. Revista de Contabilidade do Mestrado em Ciências Contábeis da UERJ – v. 15 – n. 1 – 2010.

ONUSIC, Luciana Massaro, KASSAI, Silvia, VIANA, Adriana Back Noronha. **Comparação dos Resultados de Utilização de Análise por Envoltória de Dados e Regressão Logística em Modelos de Previsão de Insolvência: Um Estudo Aplicado a Empresas Brasileiras**. FACEF PESQUISA – v. 7 – n.1 – 2004.

_____; CASA NOVA, Silvia Pereira de Castro e ALMEIDA, Fernando Carvalho de. **Modelos de Previsão de Insolvência Utilizando a Análise por Envoltória de Dados: Aplicação a Empresas Brasileiras**. RAC, 2ª Edição Especial 2007.

POUERI, Mário do Carmo. **Uma Análise de Modelos de Previsão** – Estudo Exploratório Aplicado em Empresas Mineiras. São Paulo, FEA/USP, 2002. Dissertação (Mestrado), Faculdade de Economia, Administração e Contabilidade da USP.

RAGSDALE, Cliff T. **Spreadsheet Modeling And Decision Analysis: A Practical Introduction To Management Science**. Course Technology, Inc., 1995.

REBELLO, Marcos Barbosa. **Os Modelos de Previsão de Insolvência: Uma Análise Comparativa de Seus Resultados**. Florianópolis – SC 2010. Dissertação (Mestrado em Contabilidade), Programa de Pós-Graduação em Contabilidade da Universidade Federal de Santa Catarina.

RICHARDSON, Roberto Jarry. (2012). **Pesquisa Social: Métodos e Técnicas**. 3a ed. São Paulo: Atlas.

SICSÚ, Abrahan Iaredo. **Análise Discriminante**. São Paulo, 1975. 107p. Dissertação de Mestrado, Instituto de Matemática e Estatística da Universidade de São Paulo.

SILVA, José Pereira da. **Gestão e Análise de Risco de Crédito** / José Pereira da Silva. – 9. ed., rev. e atual. – São Paulo, SP: Cengage Learning, 2016.

STUPP, Diego Rafael. **Previsão de Insolvência a Partir de Indicadores Contábeis: Evidências de Empresas Listadas na BM&FBOVESPA Nos Anos 2004-2013**. Florianópolis, SC, 2015. Dissertação (Mestrado), Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Contabilidade.