



William Peersen Rossetto Portela

**Previsão de Falência para Indústria Aérea
Americana: Calibrando o Z-Score de Altman**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia de Produção do Departamento de Engenharia Industrial da PUC-Rio.

Orientadora: Prof. Julia Lima Fleck
Co-orientadora: Prof. Denise Lima Fleck



William Peersen Rossetto Portela

**Previsão de Falência para Indústria Aérea
Americana: Calibrando o Z-Score de Altman**

Dissertação apresentada como requisito parcial para
obtenção do grau de Mestre pelo Programa de Pós-
graduação em Engenharia de Produção da PUC-Rio.
Aprovada pela Comissão Examinadora abaixo.

Prof. Julia Lima Fleck

Orientadora

Departamento de Engenharia Industrial - PUC-Rio

Prof. Denise Lima Fleck

Co-Orientadora

Universidade Federal do Rio de Janeiro - UFRJ

Prof. Fernando Luiz Cyrino Oliveira

Departamento de Engenharia Industrial - PUC-Rio

Prof. Frances Fischberg Blank

Departamento de Engenharia Industrial – PUC-Rio

Rio de Janeiro, 30 de julho de 2020

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, da autora e da orientadora.

William Peersen Rossetto Portela

Graduou-se em Engenharia de Produção pela Pontifícia Universidade Católica do Rio de Janeiro – PUC-Rio, em 2016.

Ficha Catalográfica

Portela, William Peersen Rossetto

Previsão de falência para Indústria Aérea Americana : calibrando o Z-Score de Altman / William Peersen Rossetto Portela ; orientadora: Julia Lima Fleck ; co-orientadora: Denise Lima Fleck. – 2020.
80 f. : il. color. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, 2020.
Inclui bibliografia

1. Engenharia Industrial – Teses. 2. Previsão de falência. 3. Modelo Z-Score. 4. Bootstrap. 5. Análise discriminante múltipla. I. Fleck, Julia Lima. II. Fleck, Denise Lima. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. IV. Título.

CDD: 658.5

Dedico este trabalho meu avô, Ilton, minha mãe, Ester e ao meu pai, Cairo, que espero que tenham orgulho de mim, assim como tenho deles.

Agradecimentos

Primeiramente agradeço a Deus que esteve comigo em todos os momentos dessa jornada.

Agradeço aos meus velhos Cairo, Ester e Ilton que não foram envolvidos na minha decisão de sair do meu emprego para cursar o mestrado, mas não ficaram chateados por isso e me apoiaram o tempo todo.

Agradeço aos meus antigos empregadores que entenderam e respeitaram minha saída e a empresa em si que inspirou o presente trabalho. Aos meus atuais empregadores, em especial a equipe, Carolina, Fabiana, Felipe e José, que me recebeu tão bem, sempre respeitando e incentivando meu mestrado.

Aos amigos de longa data, em especial, da escola, João e Stefano e, da graduação, Brenno e Gabriel, que mesmo eu “sumindo” nos últimos tempos, sei que sempre pude e vou poder contar com essas amizades eternas.

Agradeço ao estado do Pará e a parceira “Pontifícia/UEPA” que proporcionaram a oportunidade de eu conhecer 2 amigas que sem dúvida mudaram minha vida. Estas amizades conquistadas no mestrado valem mais do que o título de mestre em si. Larissa e Marla, nunca vou esquecer os bons e maus momentos que passamos juntos. Obrigado por sempre estarem presente quando eu precisei.

As outras amizades importantes feitas durante o curso, Brenda, Eduardo, Juliana e Thais. Aos professores e funcionários do departamento, em especial Dona Graça, um dos melhores seres humanos que conheci na minha vida. A Pontifícia e a CAPES pelos auxílios concedidos durante esses anos.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Agradeço também a minha coorientadora Professora Denise e ao graduando Pedro Soto que fizeram parte da elaboração deste trabalho.

Por fim, e não menos importante, agradeço a minha orientadora Julia. Uma parceria que foi longe de ser uma escolha óbvia. Qualquer um que olhasse uma dupla de um aluno de finanças com uma professora de gerência com viés de simulação não enxergaria dando certo. No fim, misturamos nossas especialidades e estilos e o trabalho deu certo. Agradeço por entender-me, apoiar-me e ser a orientadora que precisava. Espero que essa parceria continue, se depender de mim, continuará.

Enfim, a todos, muito obrigado!

Resumo

Portela, William Peersen Rossetto; Fleck, Julia Lima (Orientadora); Fleck, Denise Lima (Coorientadora). **Previsão de Falência para Indústria Aérea Americana: Calibrando o Z-Score de Altman**. Rio de Janeiro, 2020. 80p. Projeto de Dissertação – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

Os estudos de modelos de previsão de falência tiveram seu início há quase 90 anos, sempre com o intuito de ser uma ferramenta de gestão útil para analistas e gestores das empresas. Embora as primeiras pesquisas sejam antigas, o assunto continua atual. Diversos setores da economia passaram, ou passam, por crises ao longo do tempo e não foi diferente para a indústria de aviação. Nesse contexto, o presente trabalho usou dados históricos de indicadores financeiros das empresas aéreas americanas de um período de três décadas para elaborar quatro modelos de previsão de falência e comparar suas performances preditivas com o Modelo Z-Score. Todas as elaborações foram calibrações do Modelo Z-Score, usando técnicas de simulação e estatística. Duas usaram Análise Discriminante Múltipla (MDA) e duas utilizaram Bootstrap junto com MDA. Um par de cada método utilizou as variáveis originais do Modelo Z-Score e o outro par apresentou sugestão de novo conjunto de variáveis. Os resultados mostraram que o modelo de previsão mais preciso, com 75,0% de acerto na amostra *In-Sample* e 79,2% na *Out-of-Sample*, utilizou o conjunto original de variáveis e as técnicas Bootstrap e MDA.

Palavras-chave

Previsão de Falência, Modelo Z-Score, Bootstrap, Análise Discriminante Múltipla.

Abstract

Portela, William Peersen Rossetto; Fleck, Julia Lima (Advisor); Fleck, Denise Lima (Coadvisor). **Bankruptcy Prediction for American Aviation Industry: Calibrating the Altman's Z-Score**. Rio de Janeiro, 2020. 80p. Projeto de Dissertação – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

Studies of bankruptcy prediction models started almost 90 years ago, with the intention of being a useful management tool for analysts and managers. Although the first researches are ancient, the subject remains current. Several sectors of the economy have experienced, or are experiencing, crises over time and the aviation industry is no exception. In this context, the present work used historical data of financial indicators of American airlines over a period of three decades to develop four models of bankruptcy forecast and compared their predictive performances with the Z-Score Model. All proposed models were calibrations of the Z-Score model, using simulation and statistical techniques. Two models were generated using Discriminant Analyzes Multiple (MDA) and two using Bootstrap along with MDA. A pair of each method used the original variables of the model's Z-Score and the other pair presented a novel set of variables. Results showed that the most accurate forecasting model, with 75.0% accuracy in-sample and 79.2% out-of-sample, used the original variables of the model's Z-Score and the Bootstrap e MDA techniques.

Keywords

Bankruptcy Prediction, Z-Score Model, Bootstrap, Multiple Discriminant Analysis.

Sumário

1	Introdução	14
1.1	Objetivos	17
1.2	Estrutura da Dissertação	18
2	Modelos de Previsão de Falência	19
2.1	Modelos Univariados	19
2.2	Modelos Multivariados	21
2.2.1	Modelo Z-Score (Altman, 1968)	21
2.2.2	Modelo Z-Score Revisado (ALTMAN, 1983)	24
2.3	Modelo de Análise Logit	25
2.4	Modelo de Análise Probit	27
2.5	Outros Modelos	28
3	Revisão de Literatura: Modelos de Previsão de Falência Baseados em Z-score	30
3.1	Primeiros Passos da Busca na Literatura	30
3.2	Matriz Conceitual	34
3.3	Estatísticas Comuns aos Grupos	35
3.4	Análise Grupo 1	37
3.5	Análise Grupo 3	37
3.6	Análise Grupo 2	38
4	Metodologia	41
4.1	Análise Discriminante Múltipla (MDA)	41
4.1.1	MDA vs Regressão Linear	42
4.2	Teste F	43
4.3	Erros Falso Negativo e Falso Positivo	43
4.4	Técnica de Reamostragem Bootstrap	44
4.5	Passo-a-passo da metodologia	46
5	Resultados	50
5.1	Dados	50
5.2	Desenvolvimento dos Modelos Propostos e Resultados	52
5.2.1	Resultado Z-Score Revisado (ALTMAN,1983)	52
5.2.2	Primeiro Modelo Proposto	52
5.2.3	Segundo Modelo Proposto	54
5.2.4	Terceiro Modelo Proposto	57
5.2.5	Quarto Modelo Proposto	60
5.3	Comparando Resultados – Amostra <i>In-Sample</i>	63
5.3.1	Resultado Comparativo - Erros	63
5.3.2	Resultado Comparativo - Acertos	64

5.4 Comparando Resultados – Amostra <i>Out-of-Sample</i>	65
6 Conclusão	68
Referências bibliográficas	70
APÊNDICE 1 – LISTA COMPLETA DE VARIÁVEIS	80

Lista de Figuras

Figura 1 – Fluxograma Etapas da Pesquisa	34
Figura 2 – Gráfico de distribuição de escores.....	42
Figura 3 – Representação do uso de Bootstrap para uma amostra de dois grupos pareados	45
Figura 4 – Diferença entre os quatro modelos propostos.....	47
Figura 5 – Resumo passo-a-passo da metodologia	49
Figura 6 – Lista das Empresas da Amostra <i>In-Sample</i> de Falidas e seus pares da Amostra de Não Falidas	51
Figura 7 – Proposta do primeiro modelo.....	53
Figura 8 – Proposta do segundo modelo	54
Figura 9 – Proposta do terceiro modelo	57
Figura 10 – Proposta do quarto modelo	60
Figura 11 – Proposta dos dois modelos com melhores resultados na amostra <i>In-Sample</i> a serem testados com uma amostra <i>Out-of-Sample</i>	65
Figura 12 – Lista das Empresas da Amostra <i>Out-of-Sample</i> de Falidas.....	66
Figura 13 – Lista das Empresas da Amostra <i>Out-of-Sample</i> de Não Falidas	66

Lista de Tabelas

Tabela 1 – Indicadores selecionados por Beaver (1966)	20
Tabela 2 – Erros Falso Positivo e Falso Negativo, um ano antes da falência.....	23
Tabela 3 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência.....	23
Tabela 4 – Distinção dos grupos em função do Z-Score	24
Tabela 5 – Distinção dos grupos em função do Z-Score Revisado.....	25
Tabela 6 – Variáveis utilizadas por Ohlson (1980).....	26
Tabela 7 – Variáveis utilizadas por Zmijewski (1984).....	27
Tabela 8 – Resultado da Busca Separada.....	30
Tabela 9 – Resultado da Busca Unificada.....	31
Tabela 10 – Quantidade de Artigos por Ano de Publicação.....	31
Tabela 11 – Quantidade Total Separada por Grupo.....	33
Tabela 12 – Quantidade Disponível Separada por Grupo.....	33
Tabela 13 – Aparições das Variáveis Mais Estudadas	38
Tabela 14 – Possíveis resultados de um teste de eficiência.....	43
Tabela 15 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência do modelo Z-Score Revisado	52
Tabela 16 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência do primeiro modelo proposto.....	53
Tabela 17 – Resultado do Teste F das Variáveis.....	54
Tabela 18 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência do segundo modelo proposto.....	57
Tabela 19 – Elaborando Modelo Proposto 3: Modelos individuais para cada reamostra.	58
Tabela 20 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência do terceiro modelo proposto.....	60
Tabela 21 – Elaborando Modelo Proposto 4: Modelos individuais para cada reamostra.	61
Tabela 22 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência do quarto modelo proposto.....	63

Lista de Gráficos

Gráfico 1 – Proporção de Aparições dos Países Mais Estudados.....	35
Gráfico 2 – Proporção de Aparições das Indústrias Mais Estudadas	36
Gráfico 3 – Proporção de Aparições dos Intervalos do Tamanho das Amostras Estudadas	37
Gráfico 4 – β_1 vs <i>B Reamostras</i>	59
Gráfico 5 – β_2 vs <i>B Reamostras</i>	59
Gráfico 6 – β_3 vs <i>B Reamostras</i>	59
Gráfico 7 – β_4 vs <i>B Reamostras</i>	59
Gráfico 8 – β_5 vs <i>B Reamostras</i>	59
Gráfico 9 – <i>Z-Corte</i> vs <i>B Reamostras</i>	59
Gráfico 10 – β_1 vs <i>B Reamostras</i>	62
Gráfico 11 – β_2 vs <i>B Reamostras</i>	62
Gráfico 12 – β_3 vs <i>B Reamostras</i>	62
Gráfico 13 – β_4 vs <i>B Reamostras</i>	62
Gráfico 14 – β_5 vs <i>B Reamostras</i>	62
Gráfico 15 – <i>Z-Corte</i> vs <i>B Reamostras</i>	62
Gráfico 16 – Resultado Comparativo dos Erros Falso Negativo e Falso Positivo	64
Gráfico 17 – Resultado Comparativo dos Acertos Totais.....	65
Gráfico 18 – Percentual de erros e acertos para amostra de Falidas	67
Gráfico 19 – Percentual de erros e acertos para amostra de Não Falidas	67

1 Introdução

Bley *et al.* (2019) conceituam falência como um estado onde as perdas excedem o patrimônio líquido. Em outras palavras, falha organizacional refere-se ao desaparecimento real da organização, isto é, quando uma empresa deixa completamente de existir (AMANKWAH-AMOA, 2016). Independente da definição adotada e das causas ou fatores que a acarretam, o fato é que falência é um evento ao qual são associados “sentimentos negativos”, caracterizado por grandes perdas para todos os intervenientes (AMARO, 2015).

Há décadas acadêmicos e gestores buscam obter respostas para as perguntas “o insucesso empresarial pode ser previsto?” e “pode-se reconhecer sintomas de um fracasso que se aproxima?”.

Sharma e Mahajah (1980) apresentam um padrão geral de falência em que a gestão ineficaz aliada à incapacidade de antecipar eventos causam um estrago sistemático dos indicadores de desempenho. Com isso, e na ausência de alguma ação corretiva, essa situação de decadência da saúde financeira determina o processo de insolvência.

Pensando nisso, a pesquisa de Platt (1999) apresenta de forma bem completa este ponto. Khelil (2016), Mselmi *et al.* (2017) e Behr e Weinblat (2017) são alguns exemplos de autores que utilizaram esta referência em seus trabalhos. Platt (1999) alega que existem três fontes de informações onde se pode recorrer para detectar sintomas de falência de uma empresa: o senso comum, a análise contábil das demonstrações financeiras e as ferramentas estatísticas.

A primeira é a mais fácil de ser acessada. É o resultado do simples acompanhamento do cotidiano da companhia. Há uma gama de aspectos possíveis de serem observados no decorrer da atividade da empresa que chamam atenção sobre a possível insolvência da mesma. Como exemplos, Platt (1999) cita as opiniões emitidas por auditorias, o sucesso ou não na renegociação de linhas de crédito ou dívidas, quando for o caso, a eficácia de renegociação de contratos com fornecedores, sobretudo os de longo prazo, rescisões de importantes membros da equipe, entre alguns outros aspectos. Assim, pode-se ganhar alguma sensibilidade ao negócio da empresa e até da indústria, e recolher algumas pistas que ajudam a formular uma opinião sobre o estado financeiro de uma companhia.

A segunda fonte atenta-se puramente na análise contábil das demonstrações financeiras. Toda informação contábil é relevante, contudo as medidas de solvência e liquidez ganham mais destaques nesse caso. Por outro lado, Platt (1999) atenta sobre a facilidade de manipulação de certos indicadores; por isso é conveniente fazer certificações de que a real situação financeira da companhia é refletida em seus documentos. Para isso, as auditorias são inevitáveis e cruciais, já que a maioria dos modelos de previsão de falência, incluindo os do presente trabalho, dependem da confiabilidade dos dados financeiros das empresas.

E, por fim, a última fonte resulta do tratamento e análise dos dados da informação financeira recolhida. Este tratamento, que atualmente acontece de maneira mais recorrente, permite quantificar de forma mais fácil a correlação entre diferentes variáveis e com isso explorar melhor o “potencial preditivo” que as informações contábeis financeiras têm a oferecer.

É importante ressaltar que a distribuição dos índices contábeis muda com o tempo e, portanto, recomenda-se que os modelos sejam refeitos periodicamente (LI e FAFF, 2019; MENSAH, 1984).

Em suma, as fontes apontadas por Platt (1999) estão interligadas e podem ser definidas como base para todos os estudos que utilizam análises estatísticas para elaborar seus modelos de previsão de falência.

O debate sobre o método mais adequado para prever insolvência gira em torno de três questões: quais tipos de variáveis independentes usar, qual técnica estatística mais apropriada para os dados disponíveis e qual o modelo de seleção de variáveis é o mais adequado para se chegar a um conjunto finito de variáveis independentes dentre um conjunto maior de variáveis (DREZNER *et al.*, 2001). Como Altman (1968, p. 591) observa em relação à previsão de insolvência de empresas: “a questão torna-se: que indicadores são mais importantes na detecção de falências potenciais, quais pesos devem ser anexados a essas proporções selecionadas e como os pesos devem ser estabelecidos objetivamente?”.

A previsibilidade da insolvência tem sido estudada desde a década 1930 e diversos modelos de previsão foram elaborados ao longo dos anos (BELLOVARY *et al.*, 2007). Estes incluem, vale ressaltar, modelos de previsão de falência para empresas de Aviação Americana, que será a indústria foco do presente estudo, a exemplo de, Alan e Lapré (2018), Lu *et al.* (2015), Gritta *et al.* (2008), entre outros.

O “evento” falência está muito presente na Indústria Aérea Americana. Desde 1978, mais de uma centena de companhias entraram com pedido de falência e muitas delas deixaram de existir, incluindo gigantes conhecidas como

TWA, Eastern Air Lines e Pan Am (GRITTA *et al.*, 2008). Segundo Borenstein (2011), a perda do setor foi de quase US\$ 60 bilhões entre 1978 e 2009. Portanto, um modelo de previsão antecipado para a insolvência se mostra crucial para companhias do setor de aviação poderem prevenir perdas financeiras, além de permitir ações mitigadoras que possam tentar evitar a falência.

Previsão de insolvência, em sua maioria, é um problema de classificação binária, com duas classes: “falida” ou “não falida”. A primeira classe, apesar do nome, não significa que a empresa já faliu, mas aponta a necessidade de atenção e de ações corretivas para evitar a insolvência que aparenta ser inevitável se nada for alterado. Já a segunda classe mostra que a saúde financeira da companhia se apresenta satisfatória. O desafio inicial de um estudo neste tema se mostra com a decisão de seleção do modelo de previsão ou, no caso de trabalhos de apresentação de proposta de modelo, em qual modelo se inspirar ou se basear (KUMAR e ROY, 2016).

Altman (1968; 1983; 1994; 2007; 2015; 2016; 2017) desenvolveu modelos de previsão de falência que figuram entre os principais da literatura (KO e FUJITA, 2017). Seu modelo tradicional, o Z-Score, serve de inspiração e, sobretudo, como “ponto de partida” para inúmeros trabalhos sobre este tópico. Caldecott e Dericks (2018) afirmam que os coeficientes do Z-Score (ALTMAN, 1968) são considerados na literatura como um padrão para pesquisa.

Além disso, o modelo Z-score provou ser bastante preciso nos últimos vinte anos (ALMAMY *et al.*, 2016) e seu amplo uso indica sua aceitabilidade como uma medida simples e consistente (ALTMAN *et al.*, 2017). Como exemplos de trabalhos que utilizam esse modelo em seus estudos, seja calibrando ou aplicando, podem ser citados Bodle *et al.* (2016), Jan *et al.* (2017), Charalambakis e Garrett (2016), e diversos outros.

Ribeiro *et al.* (2012) afirmam que nas últimas três décadas, a previsão de falência da empresa se tornou uma tarefa cada vez mais importante e, até mesmo, essencial, impulsionando muitos estudos. Esta opinião é compartilhada por muitos outros pesquisadores, por exemplo: Abellán e Mantas (2014), Adamowicz e Noga (2014), Afik *et al.* (2016) e diversos outros.

A adequação e desempenho dos modelos nos tempos atuais é uma questão empírica, pois houveram muitas mudanças nas condições dos negócios e na forma como estes são praticados, como, por exemplo, o aumento de tolerância ao financiamento da dívida, mudanças nas leis de falência e ciclos econômicos variados, vide a crise de 2008. Por isso, a tendência é que os modelos se desenvolvam e suas capacidades preditivas sejam aprimoradas.

Todo e qualquer modelo desenvolvido pode, e deve, ser utilizado pelas próprias empresas e instituições para auxiliar no desenvolvimento de decisões proativas e preventivas com o objetivo de evitar dificuldades financeiras iminentes. Um sinal de alerta precoce pode reduzir perdas incorridas tangíveis (JAIKENGIT, 2004). Portanto, a precisão é uma questão importante na contabilidade, finanças, estatística e outros setores das companhias (YU *et al.*, 2014).

Previsões imprecisas podem resultar em decisões erradas e, como resultado, podem acarretar enormes perdas financeiras (OBERMANN e WAACK, 2015).

Como já mencionado, há outros modelos de previsão específicos para a indústria aérea americana. No entanto, até onde é de conhecimento, nenhuma pesquisa incorporou variáveis inéditas ao modelo Z-score (Altman, 1983), especificamente adequadas ao setor, e fez uso da técnica de reamostragem Bootstrap para calibrar o modelo. Como será visto, esta técnica traz uma maior confiabilidade no uso de qualquer amostragem, sobretudo em uma de tamanho reduzido, como é o caso desta pesquisa.

Fazendo uso dos indicadores financeiros de empresas aéreas americanas ao longo de um período de 30 anos, obtidos na agência Moody's, o foco deste estudo será calibrar o modelo original de previsão de falência de Altman (1983), gerando quatro modelos propostos. Primeiramente se aplica o método de Análise Discriminante Múltipla utilizando as variáveis originais do modelo de Z-Score Revisado (ALTMAN, 1983) bem como em um modelo adicional que utiliza variáveis alternativas testadas segundo suas eficiências preditivas. Em seguida, se aplica a técnica de reamostragem Bootstrap aos dois primeiros modelos, o que constitui um diferencial frente aos trabalhos anteriores também focados nesta indústria. O objetivo é comparar a performance de previsibilidade de todos esses modelos na indústria aérea americana: e dos quatro modelos propostos frente ao modelo Z-Score Revisado (ALTMAN, 1983).

1.1

Objetivos

O presente estudo tem como principal objetivo desenvolver um modelo de previsão de insolvência específico para a indústria de aviação americana a partir de testes, propostas e comparações de resultados de amostras *in-sample* e *out-of-sample*.

Como objetivos específicos, tem-se:

- a) Desenvolver um primeiro modelo utilizando a mesma técnica estatística que Altman (1983) usou para seu modelo, a Análise Discriminante Múltipla;
- b) Desenvolver um segundo modelo com variáveis sugeridas a partir do teste da eficiência discriminatória de indicadores financeiros;
- c) Desenvolver um terceiro modelo com o uso da técnica de reamostragem Bootstrap e a Análise Discriminante Múltipla utilizando as variáveis originais do Z-Score Revisado (ALTMAN, 1983);
- d) Desenvolver um quarto modelo com o uso da técnica de reamostragem Bootstrap e a Análise Discriminante Múltipla utilizando as variáveis do segundo modelo proposto;
- e) Comparar os resultados obtidos pelo modelo Z-Score Revisado (ALTMAN, 1983) e os quatro modelos propostos, definindo assim o mais adequado.

1.2

Estrutura da Dissertação

O presente trabalho está organizado em seis capítulos.

No primeiro, apresenta-se a parte introdutória da pesquisa, que consiste da contextualização do problema abordado, bem como a justificativa e a relevância da pesquisa. Neste capítulo também se encontram os objetivos do trabalho e a estrutura organizacional do mesmo.

Os dois capítulos seguintes exploram o referencial teórico desta pesquisa. Uma evolução dos principais modelos utilizados em trabalhos com objetivos semelhantes é apresentada, além de o desenvolvimento de uma revisão de literatura sobre o tema com diversas conclusões fundamentais para o desenvolvimento completo do trabalho.

Já o quarto aborda a metodologia aplicada no presente estudo e detalha os métodos utilizados nesta pesquisa.

No capítulo cinco, os resultados obtidos são apresentados bem como uma discussão sobre estes. Cada passo desenvolvido é explicado e a análise é abordada com comparações e estatísticas.

Por fim, no sexto capítulo, as considerações finais do presente estudo são apresentadas, além de sugestões para pesquisas futuras.

2 Modelos de Previsão de Falência

O objetivo de modificações dos modelos ao longo dos anos é melhorar cada vez mais a capacidade preditiva de possíveis insolvências (AMARO, 2015). Entretanto, este capítulo mostra que essa evolução trouxe adicionalmente uma complexidade se comparado com o modelo o Z-Score (ALTMAN, 1968).

Para Tay e Shen (2002), Bellovary *et al.* (2007), Kumar e Ravi (2007), Calderón e Cheh (2002), entre outros, os modelos de previsão de falência podem ser divididos em dois aspectos: (i) quais indicadores financeiros são usados nos testes e (ii) o método estatístico usado na previsão.

O presente capítulo irá subdividir a evolução cronológica dos modelos de previsão de falência a partir do segundo aspecto, isto é, a partir dos métodos estatísticos utilizados e o capítulo seguinte apresentará uma Revisão de Literatura cujo principal foco foi exatamente os indicadores financeiros utilizados pelos autores ao longo do tempo.

Para isso, a subdivisão do presente capítulo se fez da seguinte forma: Modelos Univariados, Modelos Multivariados, Modelo de Análise Logit e Modelo de Análise Probit. Estes são os modelos mais utilizados ao longo do tempo (BELLOVARY *et al.*, 2007). Mas, além destes, serão apresentados outros métodos mais recentes. Aziz e Dar (2006) apresentam uma revisão de literatura dividindo a evolução dos modelos de previsão de falência em três categorias: modelos estatísticos, modelos de *Artificially Intelligent Expert System* (AIES) e modelos teóricos. Os principais modelos da categoria “estatísticos” serão apresentados nos subtópicos 2.1 ao 2.4 e no subtópico 2.5 será mostrado exemplos de modelos das outras duas categorias.

2.1 Modelos Univariados

O surgimento dos modelos univariados de previsão de falências, através da análise discriminante univariada, marcou a evolução de modelos descritivos a modelos preditivos.

A maior vantagem do modelo univariado é a sua fácil aplicação pelo fato de utilizar variáveis isoladas, como será explicado adiante. Por outro lado, devido a esta metodologia, há um grande risco de empresas serem classificadas como falidas em um indicador e como não falidas em outro. Para Sheppard (1994), este modelo atingiu um nível razoável de previsibilidade, porém tendo um nível de risco pouco consistente.

Atualmente, a inclusão deste modelo em estudos é recomendada para uma investigação empírica inicial. Porém, é reconhecida pela literatura a importância dos estudos dos modelos univariados nos desenvolvidos posteriores (AGUIAR, 2013).

Beaver (1966) foi um dos primeiros estudos a usar ferramentas estatísticas para a previsão de insolvência. Ele utilizou análise discriminante univariada com um pressuposto básico de que os indicadores financeiros devem ser utilizados para a previsão, mas estes não podem ser escolhidos sem discriminação, já que uns terão mais poder de previsibilidade do que outros (COOK e NELSON, 1998).

O estudo de Beaver (1966) se baseou na comparação de indicadores financeiros entre empresas de 38 setores dos EUA. Beaver (1966) utilizou uma amostra com 79 empresas falidas e 79 empresas não falidas pareadas por setor e dimensão do período entre 1954 e 1964. O autor testou separadamente a capacidade preditiva de 30 indicadores financeiros.

Como resultado deste teste, Beaver (1966) selecionou seis indicadores com maior capacidade discriminativa (Tabela 1).

Tabela 1 – Indicadores selecionados por Beaver (1966)

Indicadores
Fluxo de Caixa/ Passivo Total
Lucro Líquido/ Ativo Total
Passivo Total/ Ativo Total
Capital de Giro/ Ativo Total
Ativo Circulante/ Passivo Circulante
Período de Crédito Nulo

Fonte: Adaptado de Beaver (1966)

Com exceção do terceiro indicador (Passivo Total/Ativo Total), em todos os indicadores espera-se que as empresas não falidas apresentem médias superiores aos valores das empresas falidas, pois são indicadores que atestam uma saúde financeira positiva de uma companhia.

Beaver (1966) concluiu que o primeiro indicador (Fluxo de Caixa/Passivo Total) apresentou a melhor capacidade preditiva, pois este classificou corretamente 87% das empresas no ano anterior à falência, seguido por Lucro Líquido/Ativo Total e Passivo Total/Ativo Total.

Em sua conclusão, o autor enuncia que “existe a possibilidade de se considerarem múltiplos indicadores simultaneamente e que nesse caso o modelo poderá ter superior capacidade de previsão”. Este é o raciocínio base dos modelos multivariados que veremos a seguir.

Pinches *et al.* (1975) e Chen *et al.* (1981) são outros exemplos de autores que utilizaram modelos univariados em suas pesquisas.

2.2

Modelos Multivariados

Os modelos multivariados se diferenciam dos univariados por considerarem uma variável dependente que é explicada de forma simultânea por diversos fatores, isto é, diversas variáveis independentes e suas combinações. Ou seja, este modelo faz uma análise conjunta de diversos indicadores financeiros (PEREIRA e MARTINS, 2015). Esses modelos apresentam capacidade preditiva superior em comparação com os univariados.

Altman (1968) propôs o Z-Score, o modelo mais usado para previsão de falência da história (KO e FUJITA, 2017). Após o clássico trabalho de Altman (1968), Deakin (1972), Blum (1974), Libby (1975) e El Hennawy e Morris (1983), entre outros, também utilizaram esta mesma metodologia em seus estudos.

2.2.1

Modelo Z-Score (Altman, 1968)

Z-Score (ALTMAN, 1968) é até os dias de hoje o mais conhecido, utilizado e importante modelo de previsão de falência (KO e FUJITA, 2017). Altman (1968) usou Análise Discriminante Multivariada (*Multiple Discriminant Analysis*, MDA) para criar uma combinação linear de cinco variáveis capazes de distinguir, com

uma elevada porcentagem de eficácia, empresas falidas de não falidas. Alamy *et al.* (2016) afirmam que foi a primeira vez que essa técnica foi publicada neste contexto.

Altman (1968) utilizou uma amostra composta por dois grupos, o primeiro era constituído por 33 empresas falidas e o segundo por 33 empresas não falidas entre os anos de 1946 e 1965. As 33 empresas solventes apresentavam características similares às do grupo oposto no que se refere ao tamanho, ao setor e aos valores dos ativos, bem como ao ano da amostra, já que os dados das empresas do Grupo 1 foram coletados das demonstrações financeiras anteriores à falência. Isto é, se uma empresa do grupo das insolventes tivesse falido no ano de 1950, os dados financeiros desta empresa usados na amostra seria de 1949, assim como os da empresa “par” do grupo das não falidas.

Inicialmente Altman escolheu, com base na literatura, 22 variáveis financeiras separadas em cinco categorias: Liquidez, Rentabilidade, Endividamento, Solvabilidade e Eficiência. Foram realizados testes de significância estatística “F” para estudar a capacidade de discriminação de cada uma das 22 variáveis. Por fim, cinco variáveis foram selecionadas. O modelo Z-Score final (Altman, 1968) é descrito pela função discriminante (1).

$$Z = 1,2X_1 + 1,4X_2 + 3,3X_3 + 0,6X_4 + 0,999X_5 \quad (1)$$

Onde:

Z = Score Discriminante

$$X_1 = \frac{\text{Capital de Giro}}{\text{Ativo Total}}$$

$$X_2 = \frac{\text{Lucros Líquidos Retidos}}{\text{Ativo Total}}$$

$$X_3 = \frac{\text{EBIT}}{\text{Ativo Total}}$$

$$X_4 = \frac{\text{Valor de Mercado}}{\text{Passivo Total}}$$

$$X_5 = \frac{\text{Vendas}}{\text{Ativo Total}}$$

O teste de significância estatística “F” mostrou que o indicador que melhor discriminava os grupos era a variável X_2 . Isso ocorre pelo fato desta ser a variável com maior amplitude média entre as empresas do primeiro grupo e do segundo. Por outro lado, o mesmo teste mostrou que a variável X_5 era a que menos discriminava.

Em seguida, Altman (1968) testou a contribuição relativa de todos os indicadores em relação à capacidade total de discriminação, e a interação entre ambas. O resultado deste teste mostrou que, diferentemente do primeiro teste, neste critério, as mais importantes eram, respectivamente, as variáveis X_3 , X_5 e X_4 .

Com a formulação finalizada, Altman classificou as observações em dois tipos de erros de previsão: erro Falso Negativo e erro Falso Positivo (BELLOVARY *et al.*, 2007). O primeiro consiste em rejeitar a hipótese nula, quando esta é verdadeira, ou seja, classificar uma empresa como falida quando na verdade ela não faliu. Analogamente, o erro Falso Positivo consiste em não rejeitar a hipótese nula quando esta é falsa, isto é, classificar uma empresa como não falida quando ela faliu.

Os resultados encontrados por Altman (1968), considerando dados um ano antes da falência, estão reproduzidos na Tabela 2.

Tabela 2 – Erros Falso Positivo e Falso Negativo, um ano antes da falência

Realidade	Previsão	
	Grupo 1 - Falidas	Grupo 2 - Não Falidas
Grupo 1 - Falidas	94% (31 empresas)	6% (2 empresas)
Grupo 2 - Não Falidas	3% (1 empresas)	97% (32 empresas)

Fonte: Adaptado de Altman (1968)

No fim, o modelo mostrou ter uma capacidade preditiva de 95% para prever a insolvência das empresas um ano antes dela ocorrer. Para continuar as análises, Altman (1968) observou os resultados de previsão para dois anos antes da falência (Tabela 3).

Tabela 3 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência

Realidade	Previsão	
	Grupo 1 - Falidas	Grupo 2 - Não Falidas
Grupo 1 - Falidas	72% (23 empresas)	28% (9 empresas)
Grupo 2 - Não Falidas	6% (2 empresas)	94% (31 empresas)

Fonte: Adaptado de Altman (1968)

Conforme pode ser observado, a capacidade preditiva do modelo diminuiu ao antecipar para dois anos antes da falência a análise da previsão. O percentual

total de acerto foi de 83%. Altman (1968) testou até cinco anos antes da falência e mostrou que, quanto maior o número de anos, menor a capacidade preditiva.

Posteriormente à análise dos resultados, Altman (1968) sugeriu a criação de três grupos distintos na classificação, ao invés dos tradicionais grupos de “falida” e “não falida”. O primeiro grupo seria o das empresas com alta probabilidade de falência, o terceiro grupo seria composto pelas empresas com baixa probabilidade de falência e um grupo intermediário onde as empresas se encontravam no que ele denominou de “Zona Cinzenta”, ou seja, quando há alguma incerteza na previsão do risco de insolvência.

Resumidamente, a separação dos grupos encontra-se na Tabela 4.

Tabela 4 – Distinção dos grupos em função do Z-Score

Z-Score	Probabilidade de Falência
$\leq 1,81$	Alta
$1,81 < \text{Z-Score} \leq 2,99$	Zona Cinzenta
$> 2,99$	Baixa

Fonte: Adaptado de Altman (1968)

Face ao exposto, quanto maior o resultado do Z-Score, melhor está, em princípio, a saúde financeira da empresa. Por outro lado, um Z-Score baixo mostra que a empresa possivelmente está com problemas financeiros sérios e com alto risco de insolvência.

2.2.2 Modelo Z-Score Revisado (ALTMAN, 1983)

No estudo de 1983, Altman usou a mesma amostra do modelo clássico adaptando-o para empresas não listadas na bolsa, conhecido como “modelo Z-Score Revisado”. Ao invés de utilizar o indicador “Valor de Mercado” na quarta variável, ele usou “Patrimônio Líquido”. Esta foi a única alteração, mas foi o suficiente para alterar todos os coeficientes assim como os Z’s de corte para probabilidade de falência. O modelo resultante encontra-se em (2).

$$Z = 0,717X_1 + 0,847X_2 + 3,107X_3 + 0,42X_4 + 0,998X_5 \quad (2)$$

E os limites de Z-Score de corte ficaram como mostra a Tabela 5.

Tabela 5 – Distinção dos grupos em função do Z-Score Revisado

Z-Score Revisado	Probabilidade de Falência
$\leq 1,23$	Alta
$1,23 < \text{Z-Score Revisado} \leq 2,99$	Zona Cinzenta
$> 2,99$	Baixa

Fonte: Adaptado de Altman (1983)

Pode ser visto que o modelo Z-Score Revisado (ALTMAN, 1983) segue o mesmo princípio do modelo clássico: quanto maior o resultado do Z-Score, melhor a saúde financeira da empresa.

O Z-Score Revisado (ALTMAN, 1983) será utilizado como base para o presente estudo, já que, embora a amostra disponível seja de empresas listadas, há a limitação da informação do indicador “Valor de Mercado”. Mais detalhes serão apresentados no capítulo de resultados.

2.3

Modelo de Análise Logit

A Análise Logit é obtida a partir de regressão logística, onde a probabilidade de insolvência acumulada assume a forma de uma função logística. Os primeiros estudos sobre este modelo surgiram no início da década de 80 como uma tentativa de solucionar algumas limitações que afetam a análise discriminante e que foram percebidas por alguns autores que usaram o modelo depois de Altman (ALTMAN e SABATO, 2007). Particularmente, o maior problema associado aos modelos multivariados é que estes assumem que as variáveis explicativas seguem uma distribuição normal multivariada com diferentes médias, mas matrizes de dispersão iguais, o que nem sempre é uma consideração adequada (SHEPPARD, 1994).

Pensando nisso, Ohlson (1980) desenvolveu um modelo para previsão de falência de modelo de regressão logística condicional, abandonando assim o pressuposto da normalidade das variáveis. Além disso, seu modelo permitia utilizar amostras não-pareadas. O autor usou uma base com 105 empresas falidas e 2058 não falidas entre os anos de 1970 e 1976.

Essa metodologia utiliza a estimação pelo Método da Máxima Verossimilhança, isto é, trata-se de um algoritmo que permite a estimação dos coeficientes β do modelo que maximizam o logaritmo natural da função de

verossimilhança. Com isso, Lo (1986) afirma que os parâmetros estimados pelo modelo Logit são mais robustos que os estimados por análise discriminante multivariada.

Outra característica deste método é que a variável dependente é uma *dummy* (binária) que assume valor 0 (zero) para as que não estão em situação de falência e 1 (um) para empresas em situação de insolvência (COSTA, 2014).

Ohlson (1980) utilizou 9 variáveis independentes, sendo duas binárias, conforme apresentado na Tabela 6.

Tabela 6 – Variáveis utilizadas por Ohlson (1980)

Variáveis
Log (Ativo Total)
Passivo Total/ Ativo Total
Capital de Giro/ Ativo Total
Ativo Circulante/ Passivo Circulante
Lucro Líquido/ Ativo Total
Receita Operacional/ Passivo Total
$\frac{NI_t - NI_{t-1}}{(NI_t + NI_{t-1})}$, onde NI _t é Net Income (Lucro Líquido) do período t mais recente
Binária igual a 1 se Passivo Total > Ativo Total; zero caso contrário
Binária igual a 1 se Lucro Líquido < 0; zero caso contrário

Fonte: Adaptado de Ohlson (1980)

Foram desenvolvidos três modelos por Ohlson (1980) para previsão de falência: um ano antes da falência; dois anos antes; e entre um e dois anos antes. No entanto, seus resultados obtiveram menor percentual de acerto em relação à análise discriminante multivariada utilizadas pelos estudos anteriores. Mesmo assim, após seu trabalho, alguns estudos passaram a utilizar modelos de regressão logística para previsão de insolvências (ALTMAN e SABATO, 2007). Como exemplos podem ser citados Gruszczynski (2019), Papanikolaou (2018), Becchetti e Sierra (2002), entre outros.

Por fim, cabe destacar que, dentre os artigos do grupo 3 da Revisão de Literatura (capítulo 3) da presente pesquisa, nas comparações de performance entre o Z-Score e o modelo Logit, o primeiro consistentemente apresentou melhor desempenho.

2.4 Modelo de Análise Probit

Hoetker (2007) afirma que o modelo Probit é parecido ao modelo Logit. Inclusive, por essa semelhança, os benefícios de sua implementação foram muito debatidos ao longo dos anos (BALCAEN e OOGHE, 2004). A principal diferença entre os modelos é que enquanto o modelo Logit assume que a probabilidade de insolvência (acumulada) segue uma distribuição logística, como visto no subtópico anterior, o modelo Probit assume que a probabilidade de falência segue uma função densidade de probabilidade associada à distribuição normal. Além desta, Balcaen e Ooghe (2004) mostram que os coeficientes estimados pelo modelo Logit são, aproximadamente, 2 vezes os estimados pelo modelo Probit.

Zmijewski (1984) analisou 81 empresas falidas e 1600 não falidas listadas na bolsa americana entre os anos de 1972 e 1978. O autor estimou o modelo com três variáveis explicativas (Tabela 7).

Tabela 7 – Variáveis utilizadas por Zmijewski (1984)

Variáveis
Lucro Líquido/ Ativo Total
Dívida Total/ Ativo Total
Ativo Circulante/ Passivo Circulante

Fonte: Adaptado de Zmijewski (1984)

Os resultados desta pesquisa sugeriram que a performance do modelo não se diferencia muito dos resultados obtidos com técnicas de amostragem aleatória (ZMIJEWSKI, 1984).

Ao longo dos anos, outros autores utilizaram esta técnica de previsão em suas pesquisas, tais como Arroyave (2018), Lin (2009) e Kasgari *et al.* (2013).

Porém, o modelo Probit continua sendo um dos menos utilizados para a previsão de falência (BELLOVARY *et al.*, 2007).

2.5 Outros Modelos

Dada a importância geral das técnicas estatísticas na previsão de falência, é natural que modelos estatísticos apresentem uso frequente, mas outras duas categorias de modelos podem ser encontradas na literatura, modelos *Artificially Intelligent Expert System* (AIES) e modelos teóricos (AZIZ e DAR, 2006).

Aziz e Dar (2006) apresentam cinco exemplos de modelos AIES: Árvore de Decisão, Raciocínio Baseado em Casos, Redes Neurais, Algoritmos Genéticos e Modelo de “Conjuntos Aproximados”. Dos trabalhos estudados pelos autores, 25% trabalharam com modelos desta categoria, o mais comum foi o modelo de Redes Neurais, com 9% do total de aparições.

Odom e Sharda (1990) introduziram a técnica de inteligência artificial de Redes Neurais para previsão de insolvências de empresas. De uma maneira resumida, a Rede Neural se baseia no funcionamento e processamento de informação semelhante ao que ocorre no cérebro humano. Particularmente, é composta por um conjunto de nós interligados entre si, com pesos correspondentes que influenciam o resultado final (COSTA, 2014).

Apesar de ser uma técnica considerada avançada, Altman *et al.* (1994) concluíram que as Redes Neurais têm um desempenho parecido aos métodos tradicionais de previsão de insolvência, podendo servir de complemento aos estudos com modelos tradicionais. Outros exemplos de autores que usaram esta técnica em suas pesquisas são Tang *et al.* (2019), Coats e Fant (1992), Falavigna (2008), Amani e Fadlalla (2017), além de outros.

A maior crítica deste modelo é o que muitos consideram a maior qualidade: a necessidade do uso de softwares e programas mais avançados. Isto acaba tornando limitada a sua utilização pelo público não especialista. Por outro lado, os modelos de falência criados anteriormente têm aplicação relativamente fácil para todos (KUBENKA e MYSKOVÁ, 2019).

Ao contrário dos modelos estatísticos e AIES, que se concentram nos sintomas de falha das empresas, os modelos teóricos são focados em determinar as causas da falência (AZIZ e DAR, 2006). Esta foi a categoria com menos aparições na pesquisa dos autores, 11% do total. Foram 4 diferentes: Decomposição de Medidas de Balanço Patrimonial (BSDM), Teoria da Ruína de

“Apostador”, Teoria da Gestão de Caixa e Teorias de Risco de Crédito, sendo o primeiro destes com o maior percentual de aparição, 4,5%.

Aziz e Dar (2006, p. 22) anunciam o BSDM como a maneira de identificar problemas financeiros examinando as mudanças na estrutura dos balanços. “Se as demonstrações financeiras de uma empresa refletirem mudanças significativas na composição dos ativos e passivos em seu balanço, é mais provável que seja incapaz de manter o estado de equilíbrio”, explicam os autores.

Houveram diversas tentativas de comparar e combinar métodos tradicionais para elaborar novos modelos. Alguns novos modelos foram propostos, mas nenhum que pudesse ser considerado “um novo marco” na evolução histórica dos modelos de previsão de falência, até porque, só com o tempo é possível identificar modelos que tornam-se “marcos” (BODLE *et al.*, 2016; HOSAKA, 2019).

Dentre os diversos tipos de técnicas de previsão, as séries temporais se destacam por serem aplicáveis em diversas áreas e setores. Morettin e Tolo (2006) definem uma série temporal como um conjunto de observações, de uma variável, medidas sequencialmente no tempo. Existem diversas formas de estudar séries temporais. A análise de uma série temporal é um mecanismo para compreensão do comportamento da série, de forma a conhecer a estrutura que gerou a série. Uma previsão a partir da série temporal procura construir um modelo matemático a partir do qual seja possível prever valores futuros (SOUSA, 2015).

Sendo assim, seria natural imaginar que esta técnica seria utilizada para pesquisas sobre previsão de falências. Porém, a elevada quantidade de *outliers* de uma série histórica de dados contábeis restringe o uso eficiente de Séries Temporais neste contexto.

3

Revisão de Literatura: Modelos de Previsão de Falência Baseados em Z-score

Este capítulo apresenta uma revisão de literatura sobre o assunto, focando na pesquisa da literatura recente sobre previsão de falência com utilização e/ou embasamento no modelo Z-Score (ALTMAN, 1968). Este está subdividido entre o passo-a-passo da revisão e os resultados dos artigos encontrados subdivididos em grupos que serão explicados adiante. Além disso, o capítulo apresenta conclusões sobre as principais descobertas que auxiliam e corroboram a realização do presente trabalho.

3.1

Primeiros Passos da Busca na Literatura

O motivo principal desta revisão de literatura foi auxiliar o objetivo específico “b” do presente estudo (seção 1.2), isto é, desenvolver um modelo proposto com variáveis inéditas sugeridas que possam substituir as originais do modelo de Z-Score Revisado (ALTMAN, 1983).

Para isso, primeiro foram escolhidas expressões em inglês que seriam usadas como palavras-chave na busca dos trabalhos. “Falência” e “Insolvência” foram as palavras escolhidas que generalizam o tema e “Modelo de Altman” junto com “Z-Score” para especificar o objetivo da revisão. A plataforma utilizada no levantamento dos dados foi a base *Scopus* por ser a plataforma mais completa que o presente trabalho obteve disponibilidade de acesso.

A Tabela 8 apresenta a quantidade de artigos encontrado pareando as palavras em quatro buscas:

Tabela 8 – Resultado da Busca Separada

Pesquisa	Qtd
TITLE-ABS-KEY ("Insolvency" AND "Z-score")	34
TITLE-ABS-KEY ("Insolvency" AND "Altman's Model")	3
TITLE-ABS-KEY ("bankruptcy" AND "Altman's Model")	38
TITLE-ABS-KEY ("bankruptcy" AND "Z-score")	101
Total	176

Fonte: Autor (2020)

Como pode ser visto, a pesquisa se limitou à busca das palavras ou expressões no resumo, no título e nas palavras-chaves (*title*, *abstract* e *keywords*). Foram encontrados 178 resultados no total. Entretanto, vale ressaltar a possibilidade de resultados repetidos entre os quatro pares. Para evitar isso, foi feita o seguinte pareamento para uma nova busca: “(Insolvência ou Falência) e (Z-Score ou Modelo de Altman)”.

Tabela 9 – Resultado da Busca Unificada

Pesquisa Unificada	Qtd
TITLE-ABS-KEY (("Insolvency" OR "bankruptcy") AND ("Altman's Model" OR "Z-score"))	160

Fonte: Autor (2020)

O resultado encontrado mostra que tinham 16 repetidos na pesquisa original.

Conforme dito anteriormente, Mensah (1984) e Li e Faff (2019) acreditam que a contabilidade, sobretudo os índices, muda com o passar do tempo e, por isso, recomenda que os modelos de previsão de falência sejam refeitos periodicamente. Pensando nisso, uma primeira análise foi feita para observar o quão recente eram os artigos pesquisados. Nenhum trabalho foi eliminado por motivo de ser muito antigo, mesmo assim a estatística se mostrou válida, como será visto. A Tabela 10 separa os 160 artigos por ano de publicação.

Tabela 10 – Quantidade de Artigos por Ano de Publicação

Ano de Publicação	Quantidade
1983	1
1996	2
1999	2
2001	1
2002	4
2003	1
2004	1
2005	3
2006	2
2007	5
2008	6
2009	4
2010	10
2011	14
2012	9
2013	15
2014	11
2015	17
2016	19
2017	23
2018	8
2019	2
Total	160

Fonte: Autor (2020)

De um total de 160 artigos, 128 foram publicados nos últimos dez anos (80,0%), o que indica que o tema e, sobretudo, a prática de utilizar o Z-Score como referência, continuam atuais.

Com a lista de 160 artigos, iniciou-se a etapa de leitura dos resumos para verificar quais eram adequados para o objetivo da revisão para incluí-los na etapa da leitura completa dos trabalhos. Esta leitura proporcionou a ideia de separação do conjunto completo de artigos por temas mais específicos.

Os 160 trabalhos foram separados em três grandes grupos:

Grupo 1: Pesquisas que apenas realizavam a aplicação do Z-Score;

Grupo 2: Pesquisas que utilizavam o Z-Score com recomendações originais de variáveis a serem testadas e inclusas;

Grupo 3: Pesquisas que faziam uma comparação entre o método do Z-Score com outros métodos.

Cada um desses grupos ajudaria de alguma forma o presente estudo. O grupo 1 mostraria o quão satisfatório está sendo considerada a aplicação do Z-

Score nos estudos recentes; o grupo 3 responde a mesma pergunta, mas ainda com a informação comparativa. Este grupo indicaria se a utilização do Z-Score de fato é adequada para desenvolver um novo método ou se este trabalho deveria buscar outro método para utilizar como ponto de partida. Dado o objetivo deste estudo se concentrar no modelo Z-Score, o grupo 2 constitui o foco da revisão de literatura, pois permite identificar variáveis que complementaríamos a presente pesquisa.

As quantidades encontradas em cada grupo encontram-se na Tabela 11.

Tabela 11 – Quantidade Total Separada por Grupo

Grupo	Qtd
1	29
2	48
3	33
Total	110

Fonte: Autor (2020)

Um total de 50 trabalhos não se encaixavam em nenhum dos grupos e foram descartados. Alguns destes apresentavam uma temática qualitativa sobre o tema, outros um viés de risco de negócio, não risco de falência, entre outros motivos.

Como dito, a plataforma escolhida para coleta de dados foi a base *Scopus*. Esta permite a leitura do título, resumo e palavras-chaves de qualquer resultado, entretanto, não são todos os artigos que podem ser coletados para leitura completa. Dos 110 trabalhos selecionados, apenas 81 estavam disponíveis para *download*.

Tabela 12 – Quantidade Disponível Separada por Grupo

Grupo	Qtd
1	23
2	39
3	19
Total	81

Fonte: Autor (2020)

A Figura 1 do fluxograma resume as etapas da pesquisa até o resultado dos 81 artigos disponíveis para leitura completa.

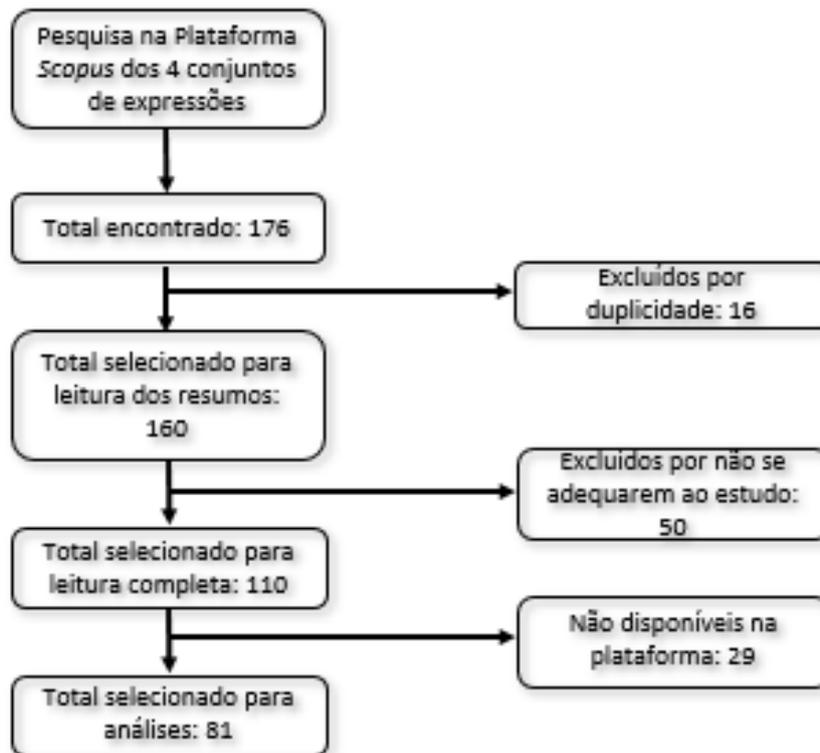


Figura 1 – Fluxograma Etapas da Pesquisa

Fonte: Autor (2020)

3.2 Matriz Conceitual

O passo seguinte, uma vez disponibilizados os artigos completos, foi elaborar a matriz conceitual focando em informações específicas coletadas dos artigos. Evidentemente, com a separação dos grupos, foram feitas as análises dos grupos separadamente: primeiro do grupo 1, depois do grupo 3 e, por fim do segundo grupo. Com isso, foram elaboradas três matrizes com focos diferentes, mas algumas estatísticas buscadas eram comuns aos três grupos, a saber, país estudado, indústria e amostra utilizada. Nesta última, mais especificamente, foram buscadas informações de tamanho, tanto das amostras de falidas e não falidas, e a duração, em anos, do período das amostragens. Nem todos os artigos forneciam as informações procuradas, mas foi possível compilar uma boa quantidade de respostas, que foram importantes para estatísticas relevantes para a presente pesquisa.

3.3 Estatísticas Comuns aos Grupos

O subtópico anterior apresentou as estatísticas buscadas em comum nos três grupos pesquisados na presente revisão de literatura, neste subtópico serão apresentados os resultados.

Inicialmente, a análise dos países estudados. O objetivo foi perceber se havia uma tendência de concentração de estudos em algum país ou continente específico. Dos 81 artigos, 66 continham esta informação, mais de 80%. Desses, 37 estudaram países que apareceram mais de uma vez na estatística. No total, 26 países diferentes apareceram nos trabalhos, mostrando a diversificação nos estudos mais modernos. O país mais estudado foi os Estados Unidos.

O Gráfico 1 apresenta as proporções de aparições dos 9 países mais estudados.

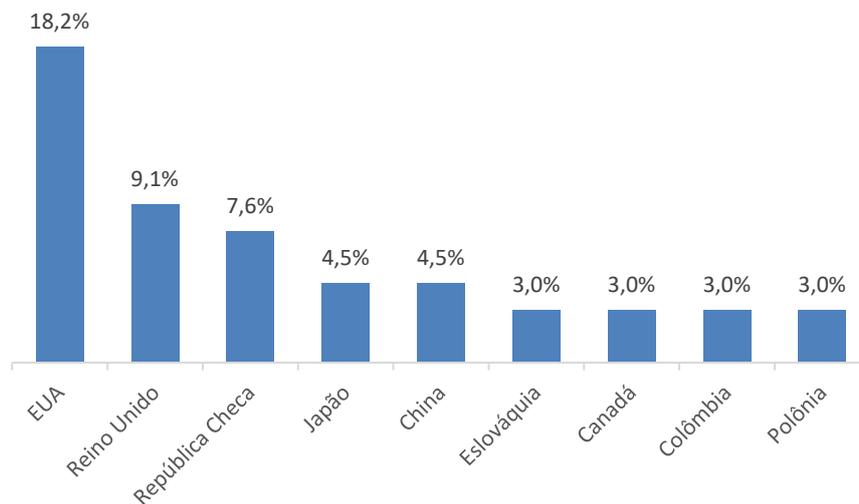


Gráfico 1 – Proporção de Aparições dos Países Mais Estudados

Fonte: Autor (2020)

Pensando por continentes, a maior parte dos estudos pesquisaram países da Europa, seguido por América do Norte e Ásia.

É importante ressaltar que a estatística se preocupa com o país estudado pelos trabalhos e não de onde eram feitos tais estudos. Tal como o presente estudo, muitos desses artigos foram produzidos em um país realizando pesquisa sobre outro. O interesse em estudar outro país pode ocorrer por diversos motivos, tais como, disponibilidade de dados, avanço da indústria, histórico de estudo, entre outros.

No total, foram 26 países diferentes estudados, além de 12 trabalhos que utilizaram amostras de mais de um país. Verifica-se uma variedade de países

considerável, mas o mesmo não acontece quando é observada a estatística sobre as indústrias pesquisadas.

Do total de artigos, apenas 63% informavam a indústria trabalhada e esses continham a variedade de 12 indústrias, além dos artigos que escrevem ter trabalhado com múltiplas indústrias (17 no total). O destaque está em bancos: 14 artigos utilizaram esse segmento, sendo que cinco especificamente trabalharam com bancos islâmicos. No Gráfico 2 aparecem as proporções de aparições das indústrias mais estudadas.

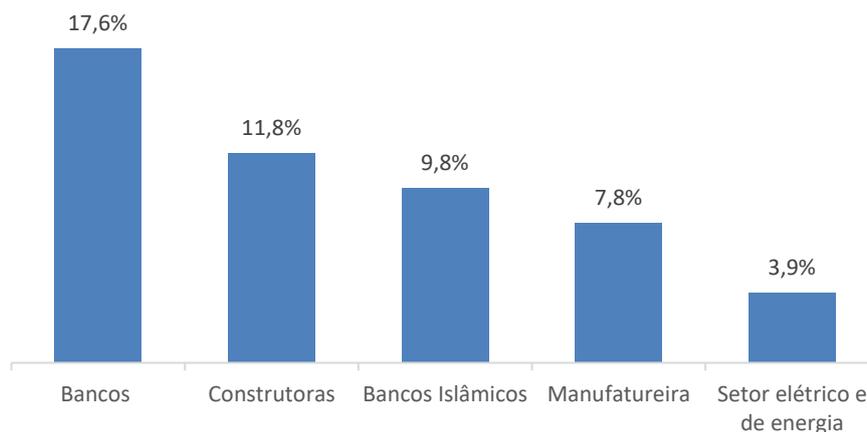


Gráfico 2 – Proporção de Aparições das Indústrias Mais Estudadas

Fonte: Autor (2020)

Por fim, outro fator que vale ser observado, também em todos os grupos, é a amostra, seu tamanho e período. O objetivo é obter parâmetro comparativo com a disponibilidade de amostra do presente estudo.

Como é impossível comparar tamanhos específicos das amostras dos trabalhos, foram separados quatro intervalos: tamanho menor que 50; entre 50 e 100; entre 100 e 1000 e acima de 1000. 53 dos 81 artigos apresentavam essa informação, 65% aproximadamente. O Gráfico 3 mostra o resultado.

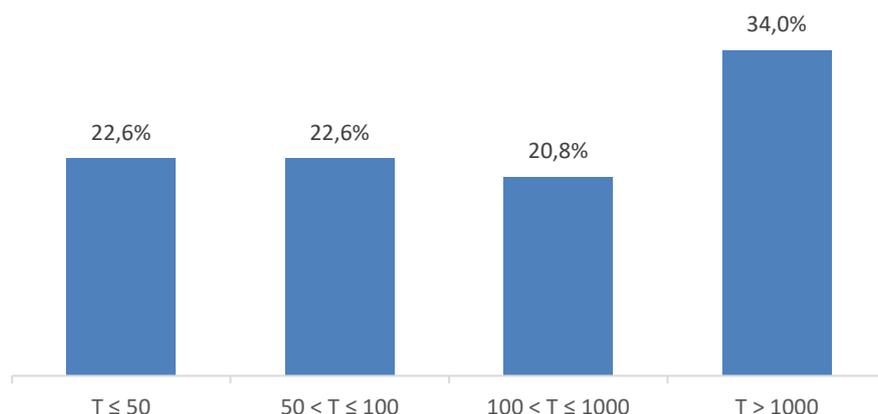


Gráfico 3 – Proporção de Aparições dos Intervalos do Tamanho das Amostras Estudadas

Fonte: Autor (2020)

Apesar da maior parte dos trabalhos utilizarem amostras acima de 50 empresas, não é incomum trabalhos com amostras consideradas pequenas: 23% dos trabalhos estudados utilizaram amostras inferiores a 50, assim como este estudo, que, por limitação de disponibilidades de dados, também utilizou amostras inferiores a 50.

Com relação à média de amplitude de anos das amostras trabalhadas, os 56 artigos que disponibilizam essa informação apresentam uma média de 9,84 anos, sendo os menores com um ano e os maiores com 21 anos.

3.4 Análise Grupo 1

Apesar de auxiliar, este grupo não é o foco desta revisão de literatura. Com isso, de maneira resumida, pode ser dito que o grupo 1 mostrou uma satisfatória precisão na performance do método e, principalmente, mostrou, na grande maioria dos artigos, que o motivo da escolha deste método para aplicação em suas pesquisas foi a importância histórica de Altman (1968) para os estudos de previsão de falência.

É relevante destacar que o clássico Z-Score (ALTMAN, 1968) não foi o único modelo utilizado nos estudos, havendo estudos que utilizaram o Z-Score Revisado (ALTMAN, 1983), de maneira semelhante ao presente estudo.

3.5 Análise Grupo 3

Assim como o grupo 1, o terceiro grupo não era o foco principal desta revisão. Contudo, é de suma relevância observar estudos que comparam o modelo Z-Score (ALTMAN, 1968) com outros mais recentes. Como visto no presente capítulo, existem diversos outros famosos modelos de previsão com outras técnicas estatísticas e metodologias utilizadas para seus desenvolvimentos. Alguns destes modelos foram utilizados nos artigos do grupo 3 para comparar com o clássico Z-Score.

O resultado, de maneira geral, mostrou uma melhor performance para o Z-Score (ALTMAN, 1968). Em quase 53% dos trabalhos, a performance deste foi superior ao método comparado. Apesar de baixo, este percentual deve ser entendido levando-se em conta que a comparação não foi entre o Z-Score (ALTMAN, 1968) e outro modelo específico, e sim, entre o Z-Score (ALTMAN, 1968) outros modelos da literatura.

3.6 Análise Grupo 2

Foi feita uma busca por alternativas de variáveis para substituir as do modelo Z-Score (ALTMAN, 1968) nos 39 artigos disponíveis do grupo 2. No total, foram encontradas 50 variáveis diferentes testadas em novos modelos. Dentre as variáveis testadas em novos modelos, algumas eram específicas para certas indústrias, como o setor bancário, enquanto a maioria era mais genérica, podendo ser aplicada em qualquer setor.

A maior repetição de variável para testes apareceu sete vezes. Retorno sobre Ativos (*Return on Assets* (ROA)) foi a mais utilizada, seguida por Retorno sobre Patrimônio Líquido (*Return on Equities* (ROE)), que apareceu em quatro estudos. Ambas foram utilizadas em diversos trabalhos que estudaram a indústria dos bancos, por exemplo. Tan e Anchor (2016) alegam que Retorno sobre Ativos é um elemento fundamental para avaliar a rentabilidade de um banco e, por isso, se tornou a variável mais comum de rentabilidade bancária.

A Tabela 13 mostra as sete alternativas de variáveis com mais aparições nos trabalhos do grupo 2. A lista completa de aparições pode ser consultada no Apêndice 1.

Tabela 13 – Variáveis Mais Estudadas

Variáveis (Eng Us)	Variáveis (Pt Br)	Aparições
ROA = Net returns/Total assets	Lucro Líquido/Ativos	(HALTEH <i>et al.</i> , 2018); (IM <i>et al.</i> , 2018); (TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017); (BOD'A e ÚRADNÍČEK, 2016); (BURGANOVA e SALAHIEVA, 2015); (THOMAS <i>et al.</i> , 2011)
ROE = Net returns/Equity	Lucro Líquido/ Patrimônio Líquido	(IM <i>et al.</i> , 2018); (BARBOZA <i>et al.</i> , 2017); (TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
Net loans/Total assets	Empréstimo/Ativos	(GAVUROVÁ <i>et al.</i> , 2017); (TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
Total assets	Ativos	(IM <i>et al.</i> , 2018); (BARBOZA <i>et al.</i> , 2017); (KARAS e REZNAKOVA, 2014)
Total Debt/Total Asset	Passivo/Ativos	(IM <i>et al.</i> , 2018); (GRDIC <i>et al.</i> , 2017); (LEE <i>et al.</i> , 2011)
Current liabilities/Total assets	Passivo Circulante/Ativo	(IM <i>et al.</i> , 2018); (CHARALAMBAKIS e GARRETT, 2016); (PHILOSOPHOV e PHILOSOPHOV, 2002)
Total debt/Equity	Passivo/ Patrimônio Líquido	(TIAN e YU, 2017); (GRDIC <i>et al.</i> , 2017); (LEE <i>et al.</i> , 2011)

Fonte: Autor (2020)

Será visto que Ativos pode ser considerado o indicador contábil mais relevante para o modelo Z-Score (ALTMAN, 1968), e algumas etapas do processo de desenvolvimento do modelo utilizaram Ativo como referência, incluindo quatro das cinco variáveis do modelo final. Observando a Tabela 13, percebe-se que a utilização de Ativos nas alternativas de variáveis sugeridas é muito forte. Das sete variáveis com mais aparições, cinco têm a presença de Ativos.

Marion (2018) define Ativos como bens e direitos de uma empresa que podem ser mensuráveis de forma monetária, que representam benefícios para a empresa, sendo presentes ou futuros. Para Indícibus *et al.* (2017), apesar desta ser uma das definições clássicas de Ativo, ela não caracteriza o que de fato Ativo representa para uma companhia.

O entendimento real do significado conceitual de Ativos é essencial para qualquer trabalho contábil (IUDÍCIBUS *et al.*, 2017). Mas, de uma maneira geral, a definição nas quais os estudos sobre falência se embasam para a comparação entre empresas falidas e não falidas é de que Ativos são bens e direitos de uma empresa que podem ser transformados em dinheiro, com maior ou menor velocidade, ou de forma mais técnica, com maior ou menor liquidez. A dificuldade ou facilidade de geração de caixa é a diferença entre evitar a falência ou entrar em processo de falência. Ou seja, Ativo é usado por ter uma grande influência em modelos de performance financeira a curto prazo (BARBOZA *et al.*, 2017).

A maioria dos estudos pesquisados na presente revisão utilizaram Ativos nas variáveis de seus modelos. Considerando a repetição de aparições, 60,5% dos artigos pesquisados utilizaram Ativos como indicador, seja no numerador, denominador ou o indicador puro.

É indiscutivelmente o indicador que mais aparece entre as sugestões de variáveis, mostrando sua importância para os artigos pesquisados, o que é condizente com a importância para o estudo base de Altman (1968) e com a importância para o presente estudo.

4 Metodologia

Este capítulo aborda o passo-a-passo da metodologia implementada para buscar os objetivos propostos. Para melhor entendimento do passo-a-passo, todos os métodos utilizados, tanto o método de modelagem, quanto a ferramenta de reamostragem ou para validação e performance de modelos, serão explicados nos subtópicos seguintes, mas podem ser encontrados com mais detalhes na literatura (Hair *et al.*, 2009; Montgomery e Runger, 2012; Efron e Tibishirani, 1993).

4.1 Análise Discriminante Múltipla (MDA)

Assim como Altman (1968) e Altman (1983), neste trabalho foi usado o método de Análise Discriminante Múltipla para elaborar os modelos de previsão de falência calibrados para a indústria da Aviação Americana.

Segundo Tabachnick e Fidell (2001), a análise discriminante tem como objetivo prever a associação a grupos a partir de um conjunto de variáveis preditoras. A variável dependente, que é a representativa dos diferentes grupos, pode ser chamada de qualitativa, enquanto as variáveis independentes, ou preditoras, são quantitativas e/ou qualitativas (JOHNSON e WICHERN, 2007).

A função discriminante pode ser explicada como uma combinação de variáveis (com seus relativos pesos) que aprimora a habilidade dos preditores de diferenciarem os grupos, sendo descrita da seguinte forma, de acordo com Cramer e Howitt (2004) e Hair *et al.* (2009):

$$Z = \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad (3)$$

Onde:

Z = Índice Discriminante

$\beta_1 \dots \beta_n$ = Pesos das n variáveis preditoras ou independentes

$X_1 \dots X_n$ = n variáveis preditoras ou independentes

Com a média dos escores Z de cada grupo, calculados pela equação (3), obtém-se o valor dos centroides, e uma comparação destes mostra o quanto os

grupos estão separados durante o teste da função discriminante (AAKER *et al.*, 2004). Quanto mais afastada é a distribuição dos escores, ou seja, quanto menor a sobreposição deles (parcela do gráfico hachurada na Figura 2), melhor é a separação dos grupos (HAIR *et al.*, 2009).

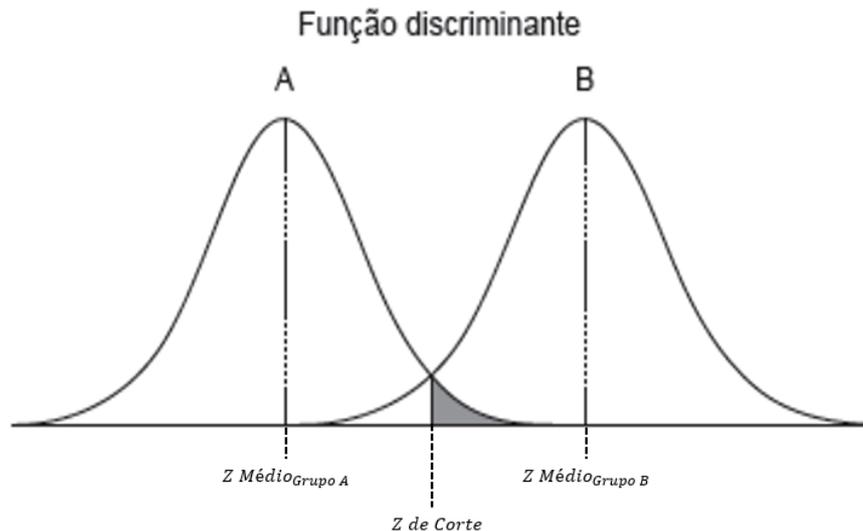


Figura 2 – Gráfico de distribuição de escores

Fonte: Adaptado de Hair *et al.* (2009)

Como pode ser visto na Figura 2, o critério que determina em qual grupo uma amostra individual será designada é o escore de corte, que é a média dos Z's de cada amostra A e B. Esta figura mostra uma situação onde dois grupos apresentam amostras do mesmo tamanho, assim como Altman (1983), e o presente trabalho também, mas é importante ressaltar que não há essa obrigatoriedade para um MDA.

4.1.1 MDA vs Regressão Linear

Apesar da semelhança na equação, Análise Discriminante Múltipla não pode ser substituída ou confundida com Regressão Linear. Nas Regressões Lineares Simples ou Múltipla, há a presença de uma variável aleatória definida como o termo erro (MONTGOMEWY e RUNGER, 2012):

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad (4)$$

Onde:

ε_i = Erro Aleatório

No caso da Análise Discriminante, o erro aparece na capacidade ou não da discriminação entre os grupos, por isso a não existência dessa variável aleatória.

4.2 Teste F

O teste F faz parte de um conjunto de testes estatísticos utilizados para validação de hipóteses, entre eles estão teste t, teste Z, teste qui quadrado, e outros (MONTGOMEWY e RUNGER, 2012).

Por definição, o teste F é utilizado para analisar a variância entre dois conjuntos distintos de dados e compará-los utilizando o teste de hipóteses (MONTGOMEWY e RUNGER, 2012). A hipótese nula (H_0) afirma que as variâncias são iguais e hipótese alternativa (H_1) diz que são diferentes, conforme ilustrado nas Equações (5) e (6), respectivamente.

$$H_0: \sigma_1^2 = \sigma_2^2 \quad (5)$$

$$H_1: \sigma_1^2 \neq \sigma_2^2 \quad (6)$$

O resultado do teste F é a conclusão de rejeitar ou não a hipótese nula a partir da comparação com um valor F-crítico. Como qualquer resultado estatístico, este está sujeito a erros que serão detalhados no subtópico a seguir.

4.3 Erros Falso Negativo e Falto Positivo

Para avaliar a eficiência da capacidade preditiva do modelo, pode ser calculado o percentual de erros Falso Negativo e Falso Positivo, que é o mesmo procedimento para o cálculo da eficácia de um teste estatístico de hipóteses. Conforme ilustrado na Tabela 14, o erro Falso Negativo consiste em rejeitar a hipótese nula, quando esta é verdadeira e o Falso Positivo consiste em não rejeitar a hipótese nula quando esta é falsa (MONTGOMERY e RUNGER, 2012).

Tabela 14 – Possíveis resultados de um teste de eficiência

Realidade	Previsão	
	Grupo 1 - Falidas	Grupo 2 - Não Falidas
Grupo 1 - Falidas	Verdadeiro Positivo	Falso Negativo
Grupo 2 - Não Falidas	Falso Positivo	Verdadeiro Negativo

Fonte: Adaptado de Montgomery e Runger (2012)

4.4 Técnica de Reamostragem Bootstrap

Bootstrap consiste em uma técnica de reamostragem com reposição. O objetivo da técnica, é a obtenção de novo(s) conjunto(s) de dados, a partir de uma amostra original (EFRON e TIBISHIRANI, 1993). Em outras palavras, o ponto chave é que a técnica permite a criação de tantas amostras quanto necessárias. Cabe ao pesquisador decidir essa quantidade, que é representada pela letra B. Desde sua introdução por Efron (1979), o método tem sido aplicado em muitos problemas estatísticos.

No presente trabalho foi escolhido a utilização da técnica para construção de 500 amostras (ou seja, $B=500$), utilizando o programa Microsoft Excel. Será visto no capítulo de resultados que esta quantidade foi testada e concluída como sendo suficiente.

Vale ressaltar que há uma peculiaridade do uso da técnica para esta pesquisa: assim como Altman (1968), a amostra é composta por dois grupos pareados, com isso, a reamostragem deve ser pareada também. A Figura 3 exemplifica esta situação (representada pelas cores de uma amostra fictícia com dois grupos de $n=5$). O grupo de Falidas da Amostra Original é composto por 5 cores diferentes e, paralelamente, o grupo de Não Falidas desta amostra é composto pelas mesmas 5 cores na mesma ordem. Isso acontece em todas as reamostras Bootstrap. Na prática, há uma reamostragem de um dos dois grupos (de Falidas ou de Não Falidas) e o outro grupo da reamostragem Bootstrap “pareia” as cores. Na Figura 3 isto está ilustrado nas Amostras Bootstrap 1, 2 e 500.

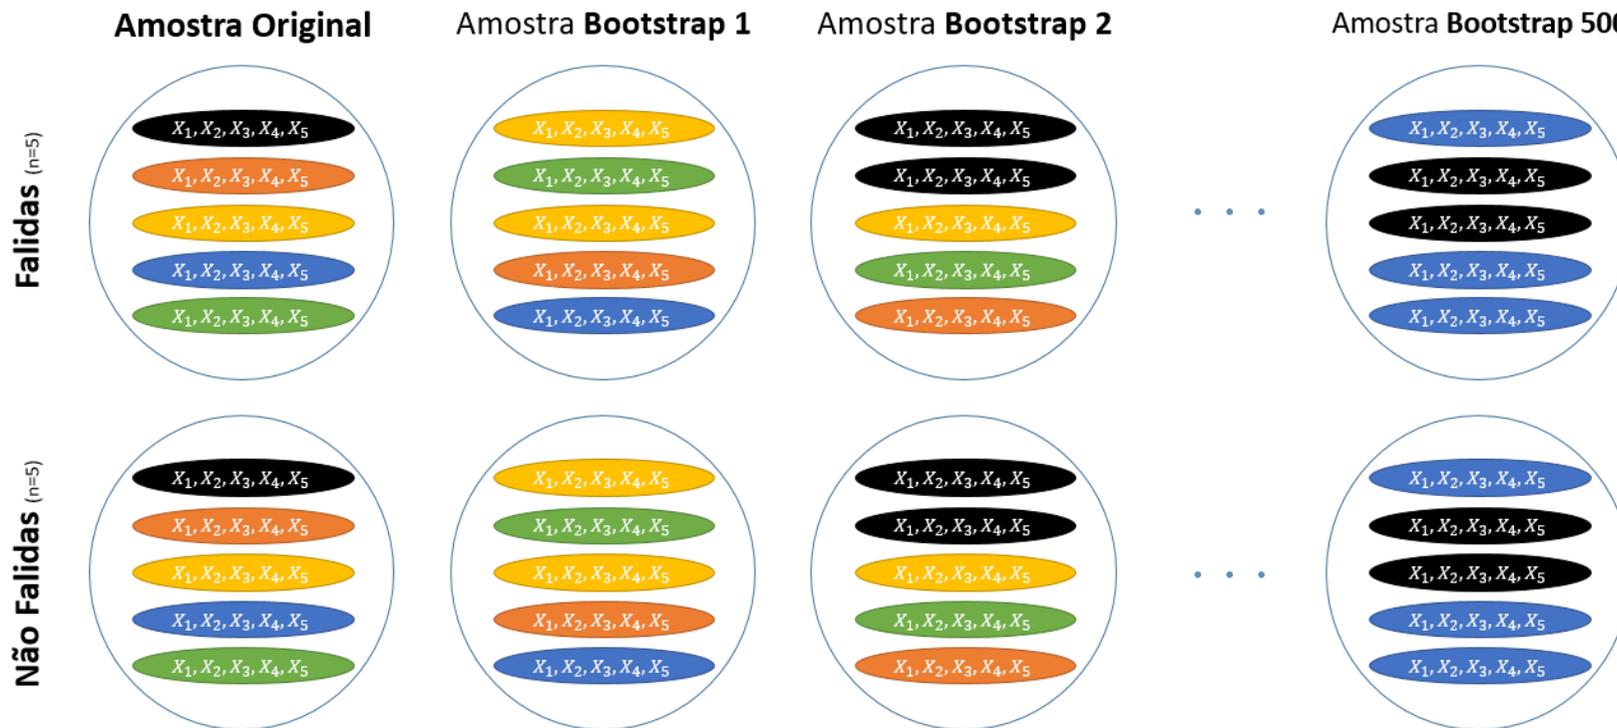


Figura 3 – Representação do uso de Bootstrap para uma amostra de dois grupos pareados

Fonte: Autor (2020)

No subtópico 4.5 será detalhada a aplicação dessas variáveis no presente estudo.

4.5 Passo-a-passo da metodologia

O primeiro passo realizado foi, a partir do conjunto de dados disponível, testar a performance preditiva do modelo Z-Score Revisado (ALTMAN, 1983) para ser usado como primeira base comparativa (detalhes em 4.3). Em seguida, assim como Altman (1968), foi realizada a aplicação do método de Análise Discriminante Múltipla (MDA), detalhado no subtópico 4.1, ainda com as variáveis originais, para calcular novos coeficientes e testou-se a capacidade preditiva deste modelo, isto é, o primeiro modelo proposto com as variáveis originais do modelo Z-Score Revisado (ALTMAN, 1983) com coeficientes calibrados.

Posteriormente, baseando-se na revisão de literatura, que resultou em sugestões de novas variáveis, elaborou-se uma lista de 19 possíveis novas variáveis a serem incorporadas a um modelo inédito de previsão de falência para a indústria de Aviação Americana. Esta lista será apresentada no subtópico 5.2.3 do capítulo de Resultados. Vale destacar que, com o objetivo de aumentar a gama de possibilidade de variáveis, foram consideradas opções de variáveis normalizadas pelo PIB anual.

A alternativa deste teste normalizando pelo PIB foi, até onde é de conhecimento, uma proposta inédita, não sendo encontrada em nenhum dos artigos da literatura. A intenção é tornar mais assertivo o conceito de comparar anos diferentes, já que o crescimento do PIB está positivamente correlacionado com o aumento no consumo e, conseqüentemente, ao aumento de receita das empresas. A comparação dos indicadores financeiros entre anos com níveis de PIBs diferentes pode resultar em resultados falhos, embora não seja regra (ALFARO *et al.*, 2019).

Com essa lista de variáveis, utilizando a técnica do teste F (detalhado no subtópico 4.2), testou-se a capacidade discriminativa destas e, com os resultados, propôs-se um conjunto das cinco variáveis com os resultados mais satisfatórios. Com esse conjunto selecionado, realizou-se o MDA, resultando no segundo modelo proposto.

Os terceiro e quarto modelos propostos utilizam a técnica de reamostragem Bootstrap. Conforme explicado no subtópico 4.4, esta técnica

resulta em 500 reamostras, isto é, 500 novas amostras pareadas de falidas e não falidas.

Para cada uma dessas reamostras foi aplicada o MDA e obtido um modelo individual:

$$Z_i = \beta_{i,1}X_1 + \beta_{i,2}X_2 + \beta_{i,3}X_3 + \beta_{i,4}X_4 + \beta_{i,5}X_5 \quad (7)$$

Onde:

$$i = 1, 2, \dots, 500$$

Com um total de 500 novos modelos, como passo seguinte, foi calculada a média de todos os coeficientes e dos Z's discriminantes obtidos de todas as 500 reamostras.

$$\beta_k = \frac{\sum_{i=1}^{500} \beta_{i,k}}{500}, \forall k = 1, 2, 3, 4, 5 \quad (8)$$

$$Z = \frac{\sum_{i=1}^{500} Z_i}{500} \quad (9)$$

Os resultados destas médias forneceram os coeficientes dos últimos dois modelos propostos. A diferença entre o terceiro e quarto modelo é que, no terceiro, as variáveis X_1 , X_2 , X_3 , X_4 e X_5 foram as originais do modelo Z-Score Revisado (ALTMAN, 1983) (e do primeiro modelo proposto), enquanto as variáveis do quarto modelo proposto foram as definidas na segunda proposta de modelo. A Figura 4 ilustra as características dos quatro modelos propostos.



Figura 4 – Diferença entre os quatro modelos propostos

Fonte: Autor (2020)

Por fim, todos os resultados foram comparados para concluir qual o modelo de previsão de falência mais adequado, tanto com a amostra original *in-sample* e uma segunda amostra *out-of-sample*. A Figura 5 apresenta o procedimento metodológico empregado neste estudo.

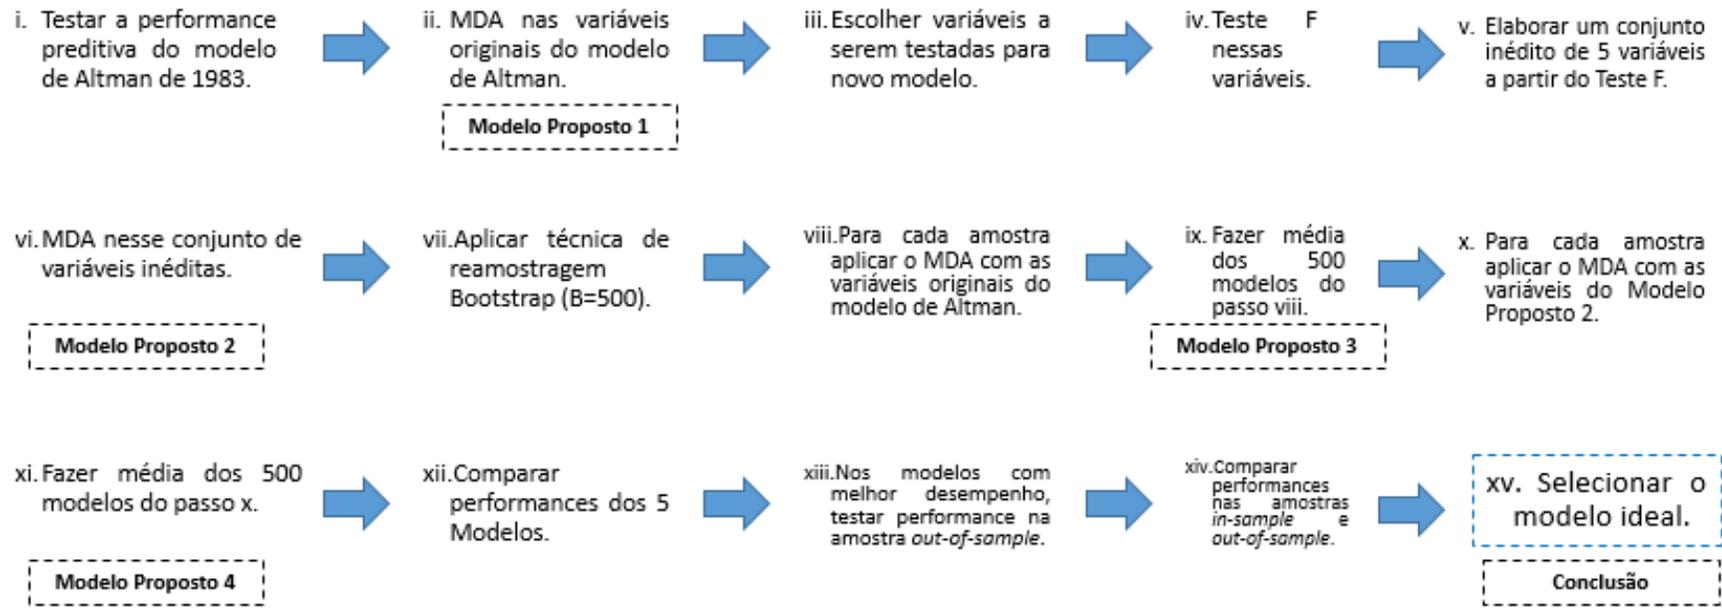


Figura 5 – Resumo passo-a-passo da metodologia

Fonte: Autor (2020)

5 Resultados

Nesta seção, será tratada toda a elaboração e desenvolvimento da pesquisa do trabalho, iniciando pela obtenção dos dados e elaboração das amostras, até os resultados comparativos. Os softwares e programas utilizados foram R-Studio versão 3.3.1. e Microsoft Excel para todos cálculos estatísticos, além de elaboração de tabelas e gráficos.

5.1 Dados

Os dados foram obtidos dos relatórios divulgados pela empresa de avaliação de risco Moody's. A Moody's divulga anualmente os resultados financeiros das empresas listadas na bolsa de Nova York, organizadas por setor de mercado, e esta pesquisa teve acesso aos relatórios das empresas de aviação.

Para elaboração da amostra, foram utilizados os relatórios de todos os anos entre 1972 e 2002, pois foram estes os relatórios que a presente pesquisa obteve acesso. Dois grupos de 16 empresas pareadas por ano e por valor total dos ativos foram compostos, um grupo de amostras de empresa falidas e outro de não falidas. Foram consideradas como "empresa falida" companhias com pedido de falência definitiva ou que entraram em concordata ou pedido de recuperação judicial.

Empresa da Amostra de Falidas	Ano	Status	Empresa Par da Amostra de Não Falidas
Universal Airlines	1972	Falida	Southern Airways
Braniff	1983	Concordata	People Express Airlines
Continental	1983	Concordata	Republic Airlines
Royale	1987	Falida	Metro Airlines
Braniff	1989	Falida	Air Wis Services
Eastern	1989	Concordata	USAIR Group
Pan Am	1991	Falida	USAIR Group
Midway Airlines	1991	Concordata	Atlantic Southeast Airlines
American West	1991	Falida	Southwest Airlines
TWA	1992	Concordata	Southwest Airlines
TWA	1995	Concordata	Southwest Airlines
Tower Air	2000	Falida	Airtran Holdings
TWA	2001	Falida	Alaska Air
Midway Airlines	2001	Falida	Atlantic Coast Airlines
US Airways	2002	Concordata	Northwest Airlines Corp.
United_UAL Corp	2002	Concordata	Delta

Figura 6 – Lista das Empresas da Amostra *In-Sample* de Falidas e seus pares da Amostra de Não Falidas

Fonte: Moody J. (1972-2002)

Vale ressaltar que o pareamento do segundo grupo seguiu os mesmos critérios de Altman (1968), com exceção do pareamento por setor, já que toda a amostra do presente trabalho é composta por empresas do mesmo setor.

Em algumas das empresas da amostra de “falidas”, não houve disponibilidade dos dados exatamente um ano antes da insolvência ou pedido de recuperação judicial. Nestes casos, havia a disponibilidade apenas de dados referentes a dois anos antes. Em função disso, optou-se por coletar toda a amostra utilizada neste estudo referente a dois anos antes da insolvência, fazendo com o que os modelos a serem propostos sejam para previsão de dois anos antes da insolvência.

Além desta, havia outra limitação nas amostras, já citada anteriormente. Embora os dados sejam de empresas listadas na bolsa, não havia disponibilidade completa da informação de “Valor de Mercado” que, como visto, é um dos indicadores necessários para o modelo clássico de Altman (1968). Devido a esta

limitação, o presente trabalho utilizou o Modelo Z-Score Revisado (ALTMAN, 1983).

5.2

Desenvolvimento dos Modelos Propostos e Resultados

Como detalhado no capítulo 4, com os dados obtidos, o passo seguinte foi elaborar os modelos propostos e comparar os resultados.

5.2.1

Resultado Z-Score Revisado (ALTMAN,1983)

Primeiramente, antes da elaboração dos modelos, foi testado o desempenho do Z-Score Revisado. Os dados coletados foram alimentados ao modelo de Altman (1983), resultando na classificação de quase todas as empresas como falidas. Isso acontece basicamente porque o retorno por ativo de uma companhia aérea apresenta um valor baixo, e como ativo total é a base para quatro variáveis do modelo, o valor de Z tende a ser baixo e, com isso, o modelo tende a qualificar todas as empresas como falidas.

No total, o percentual de acerto do modelo foi de 53,1%. O modelo classificou erroneamente apenas uma empresa da amostra de falida. Por outro lado, acertou apenas duas da amostra de não falidas, conforme pode ser visto na Tabela 15. Esse resultado mostra a necessidade de calibragem do modelo.

Tabela 15 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência do modelo Z-Score Revisado

Realidade	Previsão	
	Grupo 1 - Falidas	Grupo 2 - Não Falidas
Grupo 1 - Falidas	93,8% (15 empresas)	6,3% (1 empresa)
Grupo 2 - Não Falidas	87,5% (14 empresas)	12,5% (2 empresas)

Fonte: Autor (2020)

5.2.2

Primeiro Modelo Proposto

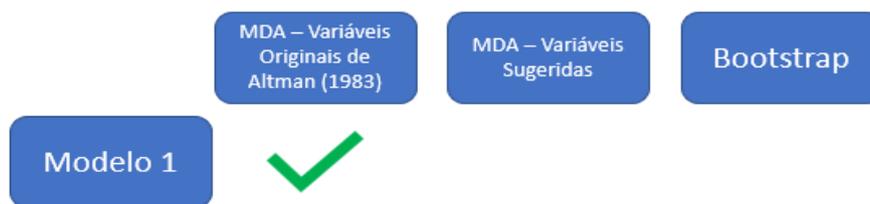


Figura 7 – Proposta do primeiro modelo

Fonte: Autor (2020)

O primeiro modelo proposto visa calibrar o valor dos coeficientes do Z-Score Revisado (ALTMAN, 1983). Para isso, foi utilizada a Análise Discriminante Múltipla (MDA) explicada no subtópico 4.1.

Modelo Original Calibrado com MDA

Para elaboração do Z-Score Revisado (ALTMAN, 1983) calibrado com MDA, foi utilizado programa R-Studio versão 3.3.1. A Análise Discriminante Múltipla resulta no seguinte modelo:

$$Z = 3,42X_1 + 4,83X_2 - 4,76X_3 + 0,93X_4 - 0,14X_5 \quad (10)$$

A média dos Z's da amostra de falidas foi -0,93 e a da amostra de não falidas +0,61. Com isso, o Z de corte ficou -0,16; acima disso, a empresa tem probabilidade baixa de falência e, analogamente, abaixo a empresa tem uma probabilidade alta.

Resultado do Primeiro Modelo Proposto

A proposta de calibragem do Z-Score Revisado (ALTMAN, 1983) resulta em um modelo completamente diferente apesar de utilizar as mesmas variáveis, diferença esta que também é percebida nos resultados. Enquanto o modelo original apresentou um acerto próximo dos 50% pelos motivos já discutidos, este primeiro modelo proposto teve um percentual de 78,1% de acerto total.

De forma mais detalhada, este modelo apresentou performance de previsão semelhante nos grupos de falidas e não falidas, eliminando a tendência do modelo original de classificar todas as empresas como falidas (Tabela 16).

Tabela 16 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência do primeiro modelo proposto

Realidade	Previsão	
	Grupo 1 - Falidas	Grupo 2 - Não Falidas
Grupo 1 - Falidas	75,0% (12 empresas)	25,0% (4 empresas)
Grupo 2 - Não Falidas	18,8% (3 empresas)	81,3% (13 empresas)

Fonte: Autor (2020)

O percentual de acertos dos dois grupos de amostras foi igual ou superior a 75,0%. Ainda assim, apesar de uma melhor performance do que o modelo de Altman (1983), este percentual corrobora a necessidade de outras alternativas de modelos propostos.

5.2.3 Segundo Modelo Proposto



Figura 8 – Proposta do segundo modelo

Fonte: Autor (2020)

O segundo modelo proposto visa elaborar um conjunto inédito de cinco variáveis. Como explicado no capítulo 4, a escolha das variáveis foi a partir do Teste F (explicado no subtópico 4.2). Para este conjunto, foi utilizada a Análise Discriminante Múltipla (MDA) explicada no subtópico 4.1.

A Tabela 17 resume os resultados obtidos a partir do teste F (Equação 11) de todas as variáveis testadas dos dois grupos da amostra de dados, incluindo as variáveis originais de Altman (1983).

$$F = \frac{\sigma_{Maior}^2}{\sigma_{Menor}^2} \quad (11)$$

Onde:

σ^2 = Variância das amostras

Tabela 17 – Resultado do Teste F das Variáveis

	Variável	Resultado do Teste F, Menor ou Maior que F-Crítico?	% relativo ao F-Crítico
Altman 1983	Working Capital/Total Assets	Menor	75,6%
	Retained Earnings/Total Assets	Maior	110,3%
	EBIT/Total Assets	Maior	182,1%
	Equity/Total Liabilities	Maior	208,6%
	Sales/Total Assets	Maior	129,7%
Variáveis Inéditas	Net returns/Total Assets	Maior	148,4%
	Net returns/Equity	Menor	3,5%
	Current Liabilities/Total Assets	Menor	77,5%
	Total debt/Total Assets	Menor	52,0%
	Net income/Total revenue	Menor	59,5%
	Current assets/Current liabilities	Maior	108,0%
	Current Liability/Sales	Menor	36,2%
	Equity/Total Liability	Menor	27,3%
	Current assets/Total liabilities	Menor	2,9%
	Passangers revenue/GNP	Menor	43,3%
	Total Revenue/GNP	Maior	232,8%
	Other Revenue/GNP	Maior	148,7%
	Net Profit/GNP	Maior	112,8%
	Retained Earnings/GNP	Menor	59,5%
	Total Asset/GNP	Menor	42,2%
	Working Capital/GNP	Menor	74,9%
	Total Liability/GNP	Maior	219,7%
EBIT/GNP	Menor	1,2%	
Total Equity/GNP	Menor	51,3%	

Fonte: Autor (2020)

Quanto maior o resultado do Teste F em relação ao F-Crítico mais discriminativa é a variável testada, sendo mais adequada para o modelo de previsão de falência proposto (HAIR *et al.*, 2009).

Modelo com Conjunto Inédito de Variáveis e MDA

Ao observar os resultados do Teste-F, primeiro ponto de destaque é o desempenho do percentual em relação ao F-Crítico satisfatório das variáveis originais do Z-Score Revisado (ALTMAN, 1983). Em função disso, duas variáveis do conjunto inédito proposto por este segundo modelo são variáveis pertencentes ao modelo original, sendo elas *Patrimônio Líquido/Passivo Total* e *EBIT/Ativo Total*, terceiro e quarto melhores desempenhos no Teste-F, respectivamente.

Outro ponto de destaque são as variáveis com a utilização da alternativa de normalização pelo PIB, muitas destas também tendo apresentado resultado satisfatório do Teste-F. Conforme explicado no subtópico 4.5, a intenção da utilização desta técnica de normalização é tornar mais assertivo o conceito de comparar anos diferentes, já que o crescimento do PIB está positivamente

correlacionado com o aumento no consumo e, conseqüentemente, ao aumento de receita das empresas.

As duas variáveis com os melhores desempenhos no percentual em relação ao F-Crítico dentre todas as testadas utilizam a técnica de normalização pelo PIB, são estas, *Receita Total* e *Passivo Total*, respectivamente.

A quinta variável incluída no conjunto do segundo modelo proposto foi a que apresentou o quinto melhor desempenho no Teste-F, *Lucro Líquido/Ativo Total*.

A Análise Discriminante Múltipla nessas variáveis resultou no segundo modelo:

$$Z = -31,71X_1 + 0,06X_2 - 0,02X_3 + 0,03X_4 + 33,38X_5 \quad (12)$$

Sendo:

$$X_1 = \frac{\text{Passivo Total}}{\text{PIB}}$$

$$X_2 = \frac{\text{EBIT}}{\text{Ativo Total}}$$

$$X_3 = \frac{\text{Lucro Líquido}}{\text{Ativo Total}}$$

$$X_4 = \frac{\text{Patrimônio Líquido}}{\text{Passivo Total}}$$

$$X_5 = \frac{\text{Receita Total}}{\text{PIB}}$$

O conjunto de variáveis ficou com um maior viés de preocupação com o passivo do que com o ativo quando comparado com o Z-Score Revisado (ALTMAN, 1983). Mais um ponto que chama atenção é que, neste conjunto, apesar do ineditismo de três variáveis, nenhum indicador financeiro é diferente em relação ao modelo original. Passivo Total, *EBIT*, Ativo Total, Lucro, Patrimônio e Receita fazem parte do modelo Z-Score Revisado (ALTMAN, 1983).

A média dos Z's da amostra de falidas foi +0,63 e a da amostra de não falidas +1,80. Com isso, o Z de corte ficou +1,21.

Resultado do Segundo Modelo Proposto

Enquanto o Z-Score Revisado (ALTMAN, 1983) apresentou um acerto próximo dos 50% e o primeiro proposto teve um percentual de 78,1% de acerto total, o segundo modelo proposto obteve um resultado de 68,8% de performance assertiva.

Diferentemente dos outros modelos, este apresentou performances de previsões iguais nos grupos de falidas e não falidas, não apresentando a

tendência de classificação das empresas, conforme pode ser observado na Tabela 18.

Tabela 18 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência do segundo modelo proposto

Realidade	Previsão	
	Grupo 1 - Falidas	Grupo 2 - Não Falidas
Grupo 1 - Falidas	68,8% (11 empresas)	31,3% (5 empresas)
Grupo 2 - Não Falidas	31,3% (5 empresas)	68,8% (11 empresas)

Fonte: Autor (2020)

Este modelo obteve um percentual assertivo inferior aos 70% na classificação dos dois grupos, distintivamente do outro modelo proposto.

A seguir será visto se outro diferencial proposto por esta pesquisa (a utilização da técnica de reamostragem Bootstrap) será assertiva.

5.2.4 Terceiro Modelo Proposto



Figura 9 – Proposta do terceiro modelo

Fonte: Autor (2020)

Os dois modelos proposto em seguida foram elaborados utilizando a técnica de reamostragem Bootstrap, explicada no subtítulo 4.4. Como já citado, a diferença entre estes modelos é que o terceiro utiliza a reamostra Bootstrap e o MDA nas variáveis originais do modelo de Altman enquanto o quarto utiliza as variáveis do segundo modelo proposto.

Modelo Original Calibrado com Bootstrap e MDA

Para início da elaboração do terceiro modelo proposto, foi realizado o processo de 500 reamostragens, explicada na seção de metodologia, e para cada uma dessas reamostras foi aplicada o MDA e obtido um modelo individual (Tabela 19).

Tabela 19 – Elaborando Modelo Proposto 3: Modelos individuais para cada reamostra

Reamostras	X1	X2	X3	X4	X5	Z-Corte
Reamostra 1	0,36	4,59	-3,27	2,21	0,26	1,035
Reamostra 2	3,92	7,94	-11,58	1,02	0,77	0,737
Reamostra 3	1,56	4,25	-5,46	1,56	-0,91	-0,777
Reamostra 4	5,61	5,35	-7,19	0,28	-0,61	-1,052
Reamostra 5	5,13	8,75	-12,21	0,17	1,09	0,745
...						
Reamostra 499	-4,24	-2,88	7,80	4,88	-2,59	-0,812
Reamostra 500	1,42	0,59	1,61	2,23	-1,96	-1,507
Média	3,04	4,07	-4,98	1,85	0,11	0,396

Fonte: Autor (2020)

Vale destacar que o percentual de acerto de cada modelo individual não é importante nesse ponto porque o terceiro modelo proposto é a média de cada um dos coeficientes nos 500 modelos individuais. O desempenho de cada modelo individual não interfere/agrega na elaboração do modelo resultante.

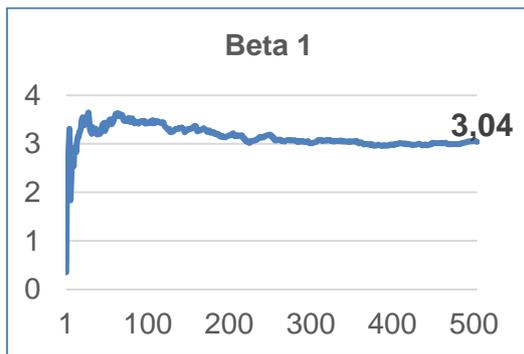
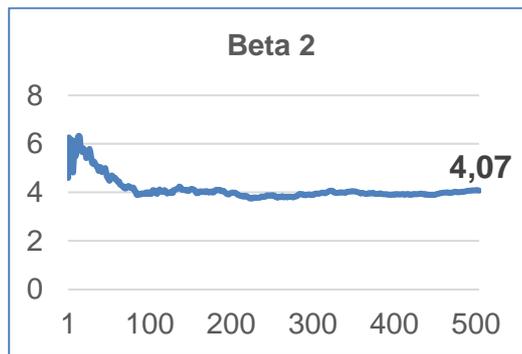
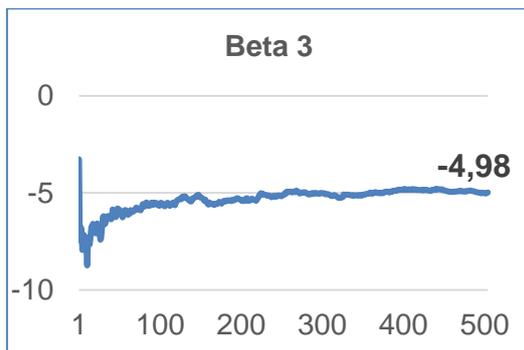
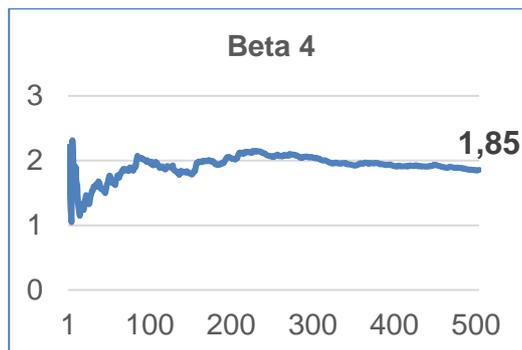
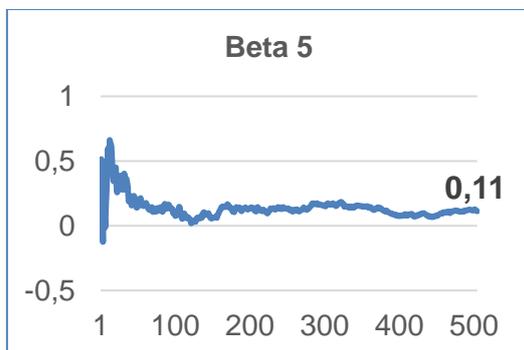
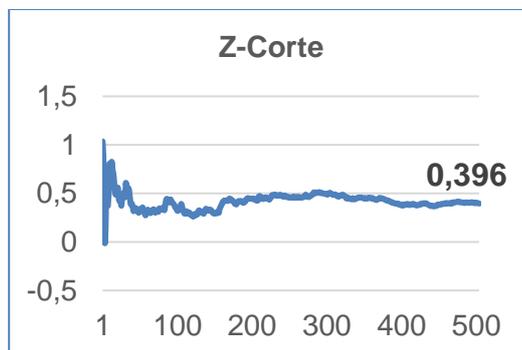
O modelo resultante obtido foi:

$$Z = 3,04X_1 + 4,07X_2 - 4,98X_3 + 1,85X_4 + 0,11X_5 \quad (13)$$

A média dos Z's da amostra de falidas foi -0,321 e a da amostra de não falidas +1,152. Com isso, o Z de corte ficou +0,396.

Em seguida foi realizado um passo adicional de checagem se uma maior quantidade de reamostras alteraria o modelo final. Para isso, foram construídos gráficos da evolução das médias dos coeficientes betas versus (B=1, ...,500) reamostras, além da evolução da média de Z de corte versus (B=1, ...,500) reamostras.

A análise dos Gráficos 4-9 evidencia dois fatos importantes. O primeiro é que o aumento de reamostras não alteraria o modelo final, além de evidenciar que a estacionariedade das variáveis acontece em torno de B=200, isto é, não havia necessidade de uma reamostra com B=500. De qualquer forma, como o presente estudo não encontrou dificuldades operacionais em trabalhar com 500 reamostras, e isto não gerar prejuízo dos resultados, esta quantidade foi mantida em todas as análises.

Gráfico 4 – β_1 vs B ReamostrasGráfico 5 – β_2 vs B ReamostrasGráfico 6 – β_3 vs B ReamostrasGráfico 7 – β_4 vs B ReamostrasGráfico 8 – β_5 vs B ReamostrasGráfico 9 – Z -Corte vs B Reamostras

Fonte: Autor (2020)

Resultado do Terceiro Modelo Proposto

A proposta de calibragem do Z-Score Revisado (ALTMAN, 1983) com reamostragem Bootstrap e MDA resulta em um modelo diferente da calibragem apenas com MDA (primeiro modelo proposto) apesar de utilizar as mesmas variáveis, diferença esta que não é percebida nos resultados.

Como todos os modelos propostos, o percentual de acerto do terceiro modelo foi superior ao modelo original. São os dois resultados comparativos mais assertivas dos modelos propostos já mostrados que podem ser utilizados como parâmetro e o terceiro modelo se mostrou o menos assertivo até o momento, com três quartos de acerto.

Ao detalhar, percebe-se que este modelo apresentou performance de previsão igual nos grupos de falidas e não falidas (Tabela 20).

Tabela 20 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência do terceiro modelo proposto

Realidade	Previsão	
	Grupo 1 - Falidas	Grupo 2 - Não Falidas
Grupo 1 - Falidas	75,0% (12 empresas)	25,0% (4 empresas)
Grupo 2 - Não Falidas	25,0% (4 empresas)	75,0% (12 empresas)

Fonte: Autor (2020)

A primeira tentativa de utilizar o Bootstrap como diferencial em relação a literatura, obteve um resultado parecido, porém, pior ao modelo com as mesmas variáveis, mas sem reamostragem, 75% de acerto contra 78,1%.

5.2.5 Quarto Modelo Proposto



Figura 10 – Proposta do quarto modelo

Fonte: Autor (2020)

O quarto modelo segue a mesma linha do terceiro utilizando as variáveis do modelo número dois, isto é:

$$X_1 = \frac{\text{Passivo Total}}{\text{PIB}}$$

$$X_2 = \frac{\text{EBIT}}{\text{Ativo Total}}$$

$$X_3 = \frac{\text{Lucro Líquido}}{\text{Ativo Total}}$$

$$X_4 = \frac{\text{Patrimônio Líquido}}{\text{Passivo Total}}$$

$$X_5 = \frac{\text{Receita Total}}{\text{PIB}}$$

Modelo Proposto 2 Calibrado com Bootstrap e MDA

Para elaboração do quarto modelo proposto, foram utilizadas as mesmas 500 reamostras já utilizadas no modelo anterior e, seguindo a mesma linha, para cada uma dessas reamostras foi aplicada o MDA e obtido um modelo individual (Tabela 21).

Tabela 21 – Elaborando Modelo Proposto 4: Modelos individuais para cada reamostra

Reamostras	X1	X2	X3	X4	X5	Z-Score
Reamostra 1	58,18	0,05	-0,01	0,03	-48,76	1,253
Reamostra 2	57,10	0,10	-0,10	0,04	-54,51	1,504
Reamostra 3	-13,02	0,01	0,08	0,03	23,30	1,170
Reamostra 4	-84,62	0,06	-0,03	0,03	92,10	1,497
Reamostra 5	147,12	-0,08	0,11	0,02	-150,00	-0,600
...						
Reamostra 499	6,03	0,11	0,00	0,03	6,83	1,632
Reamostra 500	-43,83	0,11	-0,02	0,02	50,18	1,209
Média	-23,77	0,05	-0,01	0,03	25,38	1,166

Fonte: Autor (2020)

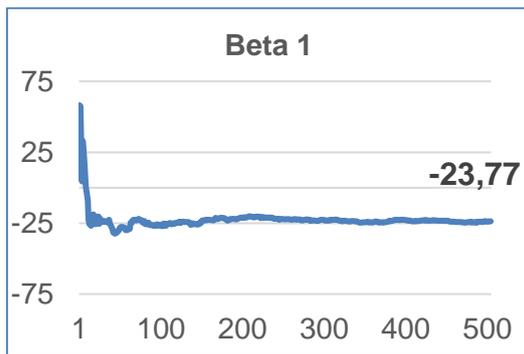
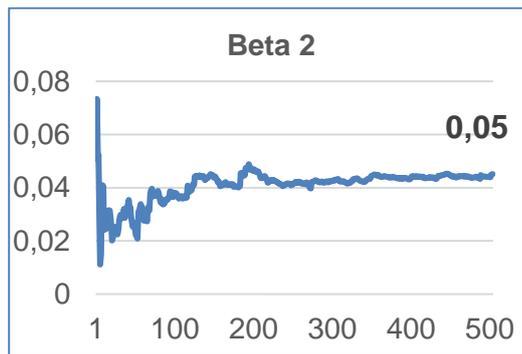
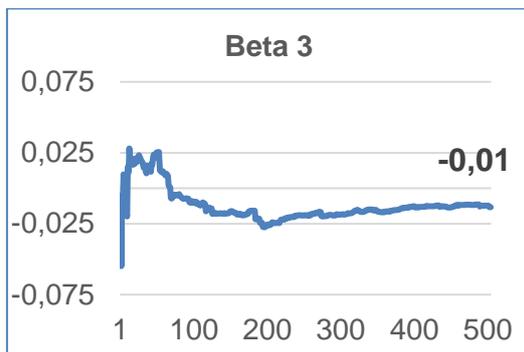
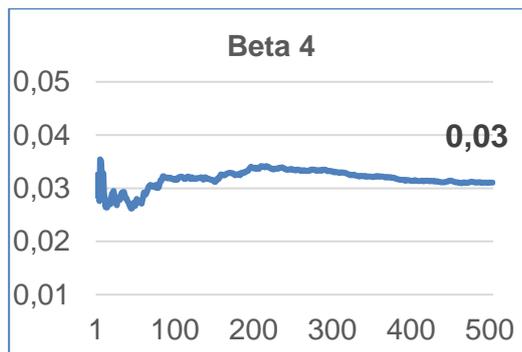
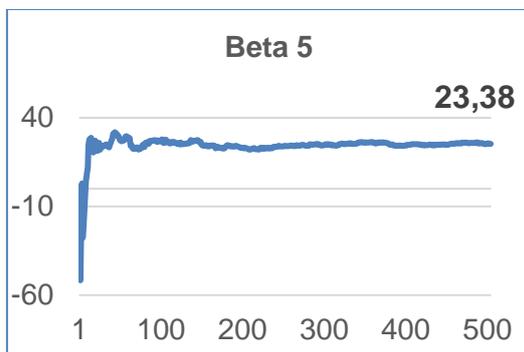
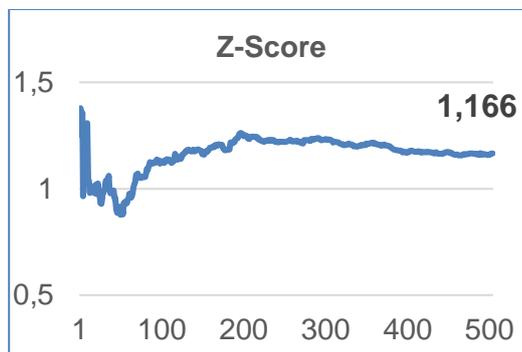
Vale destacar que, novamente, o percentual de acerto de cada modelo individual não é importante nesse ponto. Assim como o terceiro, o quarto modelo proposto é a média de cada um dos coeficientes das 500 amostras de modelos individuais e o desempenho de cada modelo individual não interfere/agrega na elaboração do modelo resultante.

O modelo resultante obtido foi:

$$Z = -23,77X_1 + 0,05X_2 - 0,01X_3 + 0,03X_4 + 25,38X_5 \quad (14)$$

A média dos Z's da amostra de falidas foi +0,671 e a da amostra de não falidas +1,815. Com isso, o Z de corte ficou +1,166.

Em seguida, foi realizado o mesmo passo adicional de checagem se uma maior quantidade de reamostras alteraria o modelo final. Mais uma vez, todos os gráficos mostraram que os valores já apresentam uma estacionariedade, o que evidencia novamente que o aumento de reamostras não alteraria o modelo final:

Gráfico 10 – β_1 vs B ReamostrasGráfico 11 – β_2 vs B ReamostrasGráfico 12 – β_3 vs B ReamostrasGráfico 13 – β_4 vs B ReamostrasGráfico 14 – β_5 vs B ReamostrasGráfico 15 – Z -Corte vs B Reamostras

Fonte: Autor (2020)

Resultado do Quarto Modelo Proposto

Diferentemente da comparação entre os terceiro e primeiro modelos propostos, a proposta de calibragem do segundo modelo com reamostragem Bootstrap e MDA não resulta em um modelo muito diferente da calibragem apenas com MDA. Os valores dos coeficientes não ficaram muito distantes entre eles, bem como o valor do Z de Corte.

De forma mais detalhada, este modelo apresentou performance de previsão igual no grupo de não falidas em relação ao de falidas (Tabela 22).

Tabela 22 – Erros Falso Positivo e Falso Negativo, dois anos antes da falência do quarto modelo proposto

Realidade	Previsão	
	Grupo 1 - Falidas	Grupo 2 - Não Falidas
Grupo 1 - Falidas	68,8% (11 empresas)	31,3% (5 empresas)
Grupo 2 - Não Falidas	31,3% (5 empresas)	68,8% (11 empresas)

Fonte: Autor (2020)

A segunda tentativa de utilizar o Bootstrap como diferencial em relação a literatura obteve o mesmo resultado ao modelo com as mesmas variáveis, mas sem reamostragem, 68,8%, diferente do outro par de modelos que a técnica Bootstrap piorou o resultado. Os dois modelos com variáveis inéditas tiveram o mesmo resultado também separando os dois grupos (falidas e não falidas), como poderá ser visto com mais detalhes na seção seguinte de comparativos de resultados.

5.3

Comparando Resultados – Amostra *In-Sample*

Para a análise comparativa de performance foram observados os percentuais de acerto, de erro Falso Negativo e erro Falso Positivo, já explicados anteriormente.

5.3.1

Resultado Comparativo - Erros

A primeira comparação de resultado de performance tratada será os erros Falso Negativo e erros Falso Positivo. Conforme pode ser visto no Gráfico 16, o modelo Z-Score Revisado (ALTMAN, 1983) quase não teve erro Falso Negativo, mas apresentou quase 90% de erro Falso Positivo para previsão, enquanto os modelos propostos obtiveram percentuais similares entres os tipos de erros e todos iguais ou abaixo de 32%.

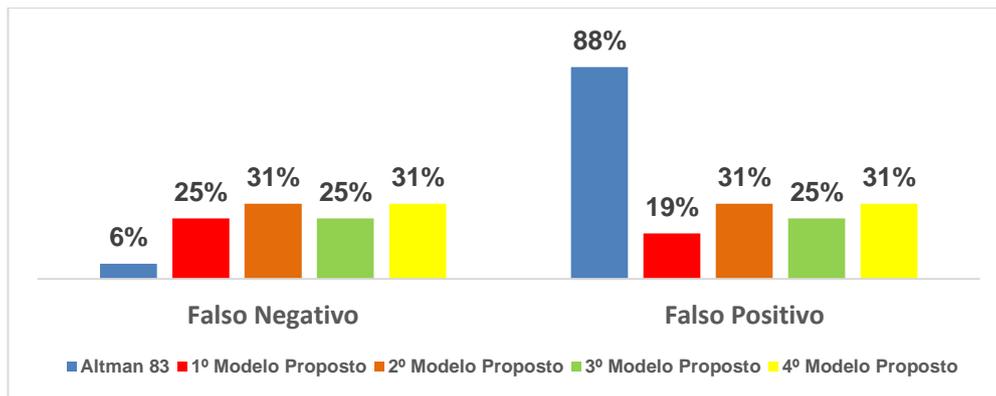


Gráfico 16 – Resultado Comparativo dos Erros Falso Negativo e Falso Positivo

Fonte: Autor (2020)

Enquanto o Z-Score Revisado (ALTMAN, 1983) classificou quase todas as empresas como falidas, os primeiro e terceiro modelos propostos, apesar de usarem as mesmas variáveis do modelo de Altman, tiveram seus coeficientes calibrados e, com isso, se tornando adaptados para a amostra, o que diminuiu naturalmente o percentual de erros e praticamente se equaliza a quantidade dos dois tipos de erros.

Com relação aos modelos propostos com variáveis inéditas, percebe-se que ambos os tipos de erros apresentaram resultados desvantajosos em relação aos outros modelos propostos. Superando inclusive os 30%, valor não alcançado pelos outros modelos.

5.3.2 Resultado Comparativo - Acertos

Para classificar qual dos modelos teve a melhor performance de previsibilidade, o ideal é observar o percentual de acerto total e não os acertos dos respectivos grupos (falida e não falida) da amostra. Os resultados mostraram que o modelo Z-Score Revisado (ALTMAN, 1983) teve uma performance bem inferior aos modelos propostos (Gráfico 17). Com a tendência de classificação de todas as empresas como falidas, o percentual total de acerto acabou próximo de 50%.

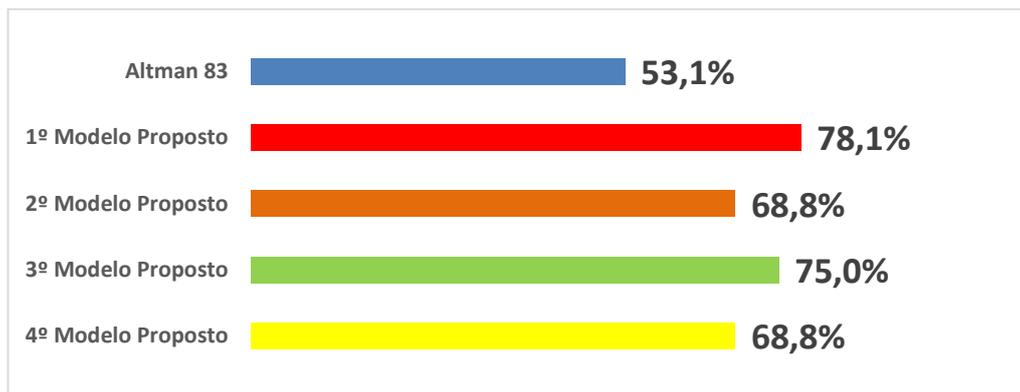


Gráfico 17 – Resultado Comparativo dos Acertos Totais

Fonte: Autor (2020)

O par de modelos que utilizam variáveis inéditas se destacam pela equiparidade. Ambos acertaram 22 das 32 classificações de *status* de falência das empresas, equivalente a 68,8% de acerto.

Já o primeiro modelo proposto apresentou um resultado próximo dos 80%, acertando 25 das 32 empresas, e o terceiro teve um desempenho um pouco abaixo, com três quartos de acerto. Estes dois apresentaram performance semelhantes, sendo assim considerados os modelos mais adequados para a proposta do presente trabalho. Para avaliar qual desses dois modelos obteve de fato uma performance mais satisfatória, uma vez que os números reportados estão próximos, este estudo propôs um teste em uma amostra *Out-of-Sample*.

5.4

Comparando Resultados – Amostra *Out-of-Sample*



Figura 11 – Proposta dos dois modelos com melhores resultados na amostra *In-Sample* a serem testados com uma amostra *Out-of-Sample*

Fonte: Autor (2020)

A amostra *Out-of-Sample* será usada para testar a aplicação dos modelos com melhor desempenho na amostra *In-Sample* (modelos 1 e 3). Esta nova

amostra não será utilizada para desenvolvimento de modelos, por isso não tem a necessidade de ser pareada, como são as amostras *In-Sample* de Altman (1968; 1983) e do presente estudo. Em função disso, foram separadas seis empresas consideradas falidas (Figura 12) e 18 não falidas (Figura 13) para compor a amostra *Out-of-Sample*.

Empresa da Amostra Out-of-Sample de Falidas	Ano	Status
Continental	1984	Concordata
Continental	1985	Falida
Eastern	1989	Concordata
Eastern	1991	Falida
TWA	1993	Concordata
TWA	1994	Concordata

Figura 12 – Lista das Empresas da Amostra *Out-of-Sample* de Falidas

Fonte: Moody J. (1984-1995)

Empresa da Amostra Out-of-Sample de Não Falidas	Ano	Empresa da Amostra Out-of-Sample de Não Falidas	Ano
TWA	1982	Northwest Airlines Corp.	1995
American Airlines	1985	Southwest Airlines	1995
TWA	1985	Delta	1996
American Airlines	1988	United	1997
Delta	1990	American Airlines	1998
USAIR Group	1992	Southwest Airlines	1999
Delta	1993	USAIR Group	1999
American Airlines	1994	American Airlines	2000
TWA	1994	Delta	2000

Figura 13 – Lista das Empresas da Amostra *Out-of-Sample* de Não Falidas

Fonte: Moody J. (1982-2001)

A motivação da utilização da técnica de reamostragem Bootstrap foi a limitação de dados de empresas falidas, mas essa limitação não acontece com as empresas não falidas, por isso esse valor alto na amostra *Out-of-Sample*.

O Gráfico 18 mostra os resultados na nova amostra de empresas consideradas falidas.

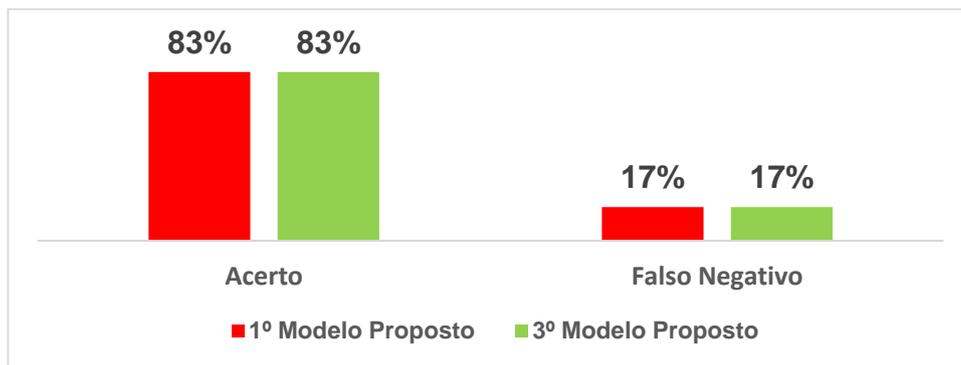


Gráfico 18 – Percentual de erros e acertos para amostra de Falidas

Fonte: Autor (2020)

Percebe-se no resultado outra igualdade na performance dos modelos. Chama atenção o desempenho quase perfeito de acerto do primeiro modelo, já que este teve desempenho superior no acerto de classificação das empresas não falidas em comparação a falidas na amostra *In-Sample*.

Este empate não ocorre na amostra *Out-of-Sample* das empresas não falidas, conforme pode ser visto no Gráfico 19. Neste caso, o terceiro modelo mantém o desempenho próximo aos 80% enquanto o desempenho do primeiro modelo piora significativamente em relação a primeira amostra, passando de 81,2% de acerto para 55,5%.

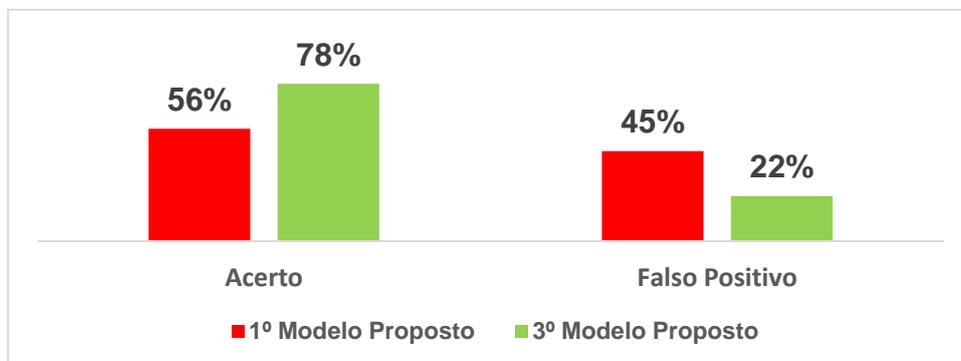


Gráfico 19 – Percentual de erros e acertos para amostra de Não Falidas

Fonte: Autor (2020)

No total, o primeiro modelo proposto obteve um percentual de acerto de 62,5% no teste com a amostra *Out-of-Sample*, enquanto o terceiro performou com um total de 79,2% de acerto, isto é, o terceiro classificou de forma correta 19 das 24 empresas, enquanto o primeiro acertou 15 classificações.

6 Conclusão

O presente trabalho teve como objetivo calibrar o modelo de previsão de falência Z-Score Revisado (ALTMAN, 1983) para a indústria de Aviação Americana, com a proposta de quatro novos modelos, e comparar a performance dos cinco modelos, indicando qual deles seria o mais adequado para o setor. Para isso, foram utilizados dados dos resultados financeiros de uma amostra de 16 empresas consideradas falidas e 16 empresas não falidas obtidos nos relatórios da Moody's. O primeiro modelo proposto foi desenvolvido com a utilização de Análise Discriminante Múltipla (MDA), assim como em (ALTMAN, 1983). A proposta do segundo foi, a partir do teste da eficiência discriminatória de diversas variáveis, apresentar um modelo com um conjunto inédito destas. Os dois modelos seguintes foram desenvolvidos com a utilização da técnica de reamostragem Bootstrap, além do uso de MDA, com as variáveis dos dois primeiros modelos.

Os resultados com a amostra *In-Sample* mostraram que o Z-Score Revisado (ALTMAN, 1983) tem performance com percentual de acerto em torno de 50% apenas. O primeiro modelo proposto apresentou um resultado de 78,1% de acerto, tendo uma performance de 25 acertos e 7 erros. O terceiro apresentou 75,0% de assertividade. Já os segundo e quarto modelos apresentaram 68,8% de percentual de acerto, isto é, uma performance de 22 acertos e 10 erros. Sendo assim, os primeiro e terceiro modelos foram considerados os modelos mais adequados considerando os resultados da amostra *In-Sample*. Foi então realizado um teste com uma amostra *Out-of-Sample* para assim ser possível afirmar qual desses dois modelos é mais adequado.

A segunda amostra continha 6 empresas consideradas falidas e 18 não falidas. O resultado mostrou uma performance positiva para ambos nos acertos em relação a amostra de falidas, mas com uma vantagem significativa no percentual total de acerto para o modelo calibrado com Bootstrap e MDA nas variáveis originais, o terceiro modelo proposto, podendo assim ser considerado o melhor. Este obteve uma performance de 79,2% de aproveitamento, enquanto o calibrado apenas com MDA nas variáveis originais acertou 63,5%.

Dentre as limitações presentes no decorrer da pesquisa, pode-se citar a indisponibilidade da consulta aos relatórios divulgados pela empresa de avaliação de risco Moody's posteriores ao ano de 2002. Em função disso, a quantidade de dados presentes no trabalho foi reduzida. Também pode-se citar como limitação da pesquisa a qualidade dos dados disponíveis, isto porque, mesmo os dados disponíveis não continham as informações completas. O maior exemplo foi a falta da variável "Valor de Mercado", por exemplo. Foi devido a esta limitação que o presente trabalho utilizou o Modelo Z-Score Revisado (ALTMAN, 1983) e não o modelo Z-Score (ALTMAN, 1968). Além destas limitações, pode ser citado também que o presente trabalho só teve acesso a dados que permitiram propor calibragem com variáveis quantitativas.

Em trabalhos futuros, podem ser testados outros conjuntos de variáveis inéditas, com outros critérios adicionais ao teste da eficiência discriminatória, inclusive, realizando um estudo com sugestões e testes de performance de variáveis qualitativas para calibragem do Z-Score Revisado (ALTMAN, 1983). O principal exemplo de variável qualitativa que pode ser explorado seria Pesquisa de Satisfação. Clientes insatisfeitos pode ser um fator determinante para a insolvência de uma companhia. Além deste, existem outros exemplos de variáveis: características dos clientes, características dos funcionários, entre outros. A dificuldade é o acesso a dados e informações, mas superando isto, um trabalho futuro explorando o universo qualitativo pode ser colaborativo para a literatura.

Referências bibliográficas

AAKER, D. A.; KUMAR, V.; DAY, G. S. Pesquisa de marketing. (2. ed.), São Paulo: **Atlas**, 2004.

ABELLÁN, J.; MANTAS, C. J. Improving Experimental Studies About Ensembles of Classifiers for Bankruptcy Prediction and Credit Scoring. **Expert Systems with Applications**, 41 (8), p. 3825–3830, 2014.

ADAMOWICZ, K.; NOGA T. Multivariate Analysis of Bankruptcy in Companies in the Wood Sector. **Sylwan**, 156 (9), p. 643–650, 2014.

ADAMOWICZ, K.; NOGA, T. Assessment applicability of selected models of multiple discriminant analyses to forecast financial situation of Polish wood sector enterprises. **Folia Forestalia Polonica**. Vol. 59(1), p.59-67, 2017.

AGARWAL, V.; TAFFLER, R. Comparing the performance of market-based and accounting-based bankruptcy prediction models. **Journal of Banking & Finance**, Vol. 32, Issue 8, p. 1541-1551, 2008.

AFIK, Z.; ARAD, O.; GALIL, K. Using Merton Model for Default Prediction: An Empirical Assessment of Selected Alternatives. **Journal of Empirical Finance**, 35, p. 43–67, 2016.

AGUIAR, A. Modelo de Previsão de Falência Aplicado às PME Portuguesas. Dissertação de Mestrado em Finanças. **Universidade do Porto**, 2013.

ALAN, Y.; LAPRE, M. Investigating operational predictors of future financial distress in the U.S. airline industry. **Production and Operations Management**, 27(4), p. 734-755, 2018.

ALFARO, L.; ASIS, G.; CHARI, A.; PANIZZA, U. Corporate debt, firm size and financial fragility in emerging markets. **Journal of International Economics**, 118, p. 1–19, 2019.

ALMAMY, J.; ASTON, J.; NGWA, L.N. An evaluation of Altman's Z-score using cash flow ratio to predict corporate failure amid the recent financial crisis: Evidence from the UK. **Journal of Corporate Finance**, 36, pp. 278-285, 2016.

ALTMAN, E. I. Financial Ratios, Discriminate Analysis and the Prediction of Corporate Backruptcy. **The Journal of Finance**, p. 589-609, 1968.

ALTMAN, E. I. Corporate Financial Distress A Complete Guide to Predicting, Avoiding, and Dealing with Bankruptcy. Nova York: Wiley Interscience, **John Wiley and Sons**, 1983.

ALTMAN, E. I.; MARCO, G.; VARETTO, F. Corporate distress diagnosis: comparisons using linear discriminant analysis and neural networks (the Italian experience). **Journal of Banking and Finance**, Vol. 18, pp. 505-529, 1994.

ALTMAN, E.I.; BRANCH, B. The bankruptcy system's chapter 22 recidivism problem: How serious is it? **The Financial Review**, Vol. 50, Issue 1, p. 1-26, 2015.

ALTMAN, E. I.; SABATO, G. Modeling Credit Risk for SMEs: Evidence from the US Market. **Abacus**, v. 43, n. 3, p. 332-357, 2007.

ALTMAN, E. I.; IWANICZ-DROZDOWSKA, M.; LAITINEN, E.K.; SUVAS, A. Financial Distress Prediction in an International Context: A Review and Empirical Analysis of Altman's Z-Score Model. **Journal of International Financial Management and Accounting**, 28(2), pp. 131-171, 2017.

AMANI, F. A.; FADLALLA, A. M. Data mining applications in accounting: A review of the literature and organizing framework. **International Journal of Accounting Information Systems**, 24, p. 32–58, 2017.

AMANKWAH-AMOA, J. An Integrative Process Model of Organisational Failure. **Journal of Business Research**, 69(9), p. 3388-3397, 2016.

AMARO, D. J. S. Modelos de Previsão de Falência: O setor bancário português. Dissertação de Mestrado em Análise Financeira: **Coimbra Business School**, 2015.

APPIAH, K.O.; ABOR, J. Predicting corporate failure: Some empirical evidence from the UK. **Benchmarking: An International Journal**, Vol. 16, Issue 3, pp. 432-444, 2009.

ARROYAVE, J. A comparative analysis of the effectiveness of corporate bankruptcy prediction models based on financial ratios: Evidence from Colombia. **Journal of International Studies**, Vol 11(1), p. 273–287, 2018.

AZIZ, M. A.; DAR, H. A. Predicting corporate bankruptcy: where we stand? **Corporate Governance**, 6(1), 18-33, 2006.

BALCAEN, S.; OOGHE, H. 35 Years of Studies on Business Failure: An Overview of the Classic Statistical Methodologies and Their Related Problems. **The British Accounting Review**, 38(1), 63-93, 2004.

BARBOZA, F.; KIMURA, H.; ALTMAN, E. Machine Learning Models and Bankruptcy Prediction. **Expert Systems With Applications** 83, pp. 405–417, 2017.

BĂRBUȚĂ-MIȘU, N.; MAZILESCU, V. Assessing the predictive power of the multifactorial models of the bankruptcy risk. **Risk governance & control: financial markets & institutions**, Vol. 1, Issue 1, p. 112-123, 2011.

BASOVNÍKOVÁ, M.; KONEČNÝ, M.; DUBOVÝ, R.; MASAROVÁ, A. The use of the altman model in evaluation of economic performance of a corporation in the crisis period in the building sector in the Czech Republic. *Acta Universitatis Agrivulturae et Silviculturae Mendeliana Brunensis*, Vol. 66(2), p. 109-421, 2018.

BAUER, J.; AGARWAL, V. Are hazard models superior to traditional bankruptcy prediction approaches? A comprehensive test. **Journal of Banking & Finance**, Vol. 40(1), p. 432-442, 2014.

BEAVER, W. H. Financial Ratios as Predictors of Failure. **Journal of Accounting Research**, Vol. 4, Empirical Research in Accounting Selected Studies, pp. 71-111, 1966.

BECCHETTI, L.; SIERRA, J. Bankruptcy Risk and Productive Efficiency in Manufacturing Firms. **Journal of Banking and Finance**, 27, pp. 2099-2120, 2002.

BEHR, A.; WEINBLAT, J. Default prediction using balance-sheet data: a comparison of models. **Journal of Risk Finance**, 18(5), p. 523-540, 2017.

BELLOVARY, J. L.; GIACOMINO, D. E.; AKERS, M. D. A Review of Bankruptcy Prediction Studies: 1930 to Present. **Journal of Financial Education**, Vol. 33, pp. 1-42, 2007.

BLEY, J.; SAAD, M.; SAMET, A. Auditor choice and bank risk taking. **International Review of Financial Analysis**, 91, p. 37-52, 2019.

BLUM, M. Failing Company Discriminant Analysis. **Journal of Accounting Research**, p.1-25, 1974.

BOĎA, M.; ÚRADNÍČEK, V. The portability of altman's Z-score model to predicting corporate financial distress of Slovak companies. **Technological and Economic Development of Economy**, Vol. 22(4), p.532-553, 2016.

BODLE, K.A.; CYBINSKI, P.J.; MONEM, R. Effect of IFRS adoption on financial reporting quality Evidence from bankruptcy prediction. **Accounting Research Journal** 29(3), pp. 292-312, 2016.

BOLAT, A. Evaluating the current financial state of banking sector in Kazakhstan using Altman's model, Bankometer model. **Revista Espacios**, Vol. 38 (Nº 48). P. 4, 2017.

BORENSTEIN, S. On the persistent financial losses of US airlines: A preliminary exploration. **National Bureau of Economic Research, Working paper #16744**, 2011.

BURGANOVA, R.A.; SALAHIEVA, M.F. Z-score for bankruptcy forecasting of the companies producing building materials. **Asian Social Science**, Vol. 11, No. 11, p.109-114, 2015.

CALDECOTT, B.; DERICKS, G., Empirical calibration of climate policy using corporate solvency: a case study of the UK's carbon price support. **Journal of Climate Policy**, 18(6), pp. 766-780, 2018.

CALDERON, T. G.; CHEH, J. J. A Roadmap for future neural networks research in auditing and risk assessment. **International Journal of Accounting Information Systems**, 3, p. 203–236, 2002.

CHARALAMBAKIS, E.C.; GARRETT, I. On the prediction of financial distress in developed and emerging markets: Does the choice of accounting and market information matter? A comparison of UK and Indian Firms. **Review of Quantitative Finance and Accounting**, 47(1), 2016.

CHEN, K.; SHIMERDA, T. An Empirical Analysis of Useful Financial Ratios. **Financial Management**, Vol. 10(1), pp. 51-60, 1981.

COATS, P.; FANT, L. A Neural Network Approach to Forecasting Financial Distress. **The Journal of Business Forecasting Methods & Systems**, Vol. 10(4), pp. 9-12, 1992.

COOK, R. A.; NELSON, J. L. A Conspectus of Business Failure Forecasting. **The Journal of Finance**, April, pp. 589–609, 1998.

COSTA, H. A. Modelo de Previsão de Falência: o Caso da Construção Civil em Portugal. Dissertação de Mestrado em Finanças Empresariais: **Universidade do Algarve**, 2014.

CRAMER, D.; HOWITT, D. L. The SAGE dictionary of Statistics. London: **Sage Publications**, 2004.

DEAKIN, E. A Discriminant Analysis of Predictors of Business Failure. **Journal of Accounting Research**, 10(1), pp. 167-179, 1972.

DOLEJŠOVÁ, M. Is it worth comparing different bankruptcy models? **Acta Universitatis Agrivulturae et Silviculturae Mendeliana Brunensis**, Vol. 63, No. 2, p. 525-531, 2015.

DREZNER, Z.; MARCOULIDES, G.; STOHS, M. Financial Applications of a Tabu Search Variable Selection Model. **Journal of Applied Mathematics and Decision Sciences**, 5(4), 215–234, 2001.

EFRIM, B. J.; KENNEDY, D.B.; SUN, J.Y. Predicting business failures in Canada. **Canadian Accounting Perspectives**, Vol. 6, No. 2, p. 141-165, 2007.

EFRON, B. Bootstrap Methods: Another Look at the Jackknife. **The Annals of Statistics**, p. 1-26, 1979.

EFRON, B.; TIBISHIRANI, R. J. An Introduction to the Bootstrap. Nova York: **John Wiley and Sons**, 1993.

EL HENNAWY, R.; MORRIS, R. The Significance of Base Year in Developing Failure Prediction Models. **Journal of Business Finance & Accounting**, p. 209-223, 1983.

GAVUROVÁ, B.; JANKE, F.; PACKOVÁ, M.; PRÍDAVOK, M. Analysis of impact of using the trend variables on bankruptcy prediction models performance. **Ekonomický casopis**, Vol. 65, Issue 4, p. 370-383, 2017.

GRDIĆ, Z.Š.; NIŽIĆ, M.K.; MAMULA, M. Insolvency in the Republic of Croatia. **Economic Research-Ekonomska Istrazivanja**, Vol. 30, No. 1, p. 1693-1704, 2017.

GRICE, J.S., INGRAM, R.W. Tests of the generalizability of Altman's bankruptcy prediction model. **Journal of Business Research**, Vol. 54, Issue 1, p. 53-61, 2001.

GRITTA R. D.; ADRANGI B; DAVALOS S; BRIGHT D. A review of the history of air carrier bankruptcy forecasting and the application of various models to the US airline industry, 1980–2005. *History of Insolvency and Bankruptcy: from an International Perspective* 193–214, 2008.

HAIR, J. F. Jr.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E. Análise multivariada de dados. 6ª ed., **Porto Alegre**, pp. 221-322, 2009.

HAJEK, P.; OLEJ, V.; MYSKOVA, R. Forecasting corporate financial performance using sentiment in annual reports for stakeholders' decision-making. **Tecnological and Economic Development of Economy**, Vol. 20(4), p. 721-738, 2014.

HALTEH, K.; KUMAR, K.; GEPP, A. Financial distress prediction of Islamic banks using tree-based stochastic techniques. **Managerial Finance**, Vol. 4, Issue 6, pp. 759-773, 2018.

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

HILLEGEIST, S.A.; KEATING, E.K.; CRAM, D.P.; LUNDSTEDT, K.G. Assessing the probability of bankruptcy. **Review of Accounting Studies**, Vol. 9, Issue 1, pp. 5-34, 2004.

HOETKER, G. The Use of Logit and Probit Models in Strategic Management Research Critical Issues. **Strategic Management Journal**, Vol. 28, pp. 331-343, 2007.

HOSAKA, T. Bankruptcy prediction using imaged financial ratios and convolutional neural networks. **Expert Systems with Applications**, 117, p. 287–299, 2019.

IM, H.; MINCHIN, E.; HAKIM, H.; ZHANG, Y. Monitoring the financial trends of construction firms in Korea, Japan, and the United States by using bankruptcy prediction model. **Construction Research Congress**, 2018.

IUDÍCIBUS, S.; MARION, J. C.; FARIA, A. C. Introdução à Teoria da Contabilidade. 6ª ed., São Paulo: **Atlas**, 2017.

JACKSON, R.H.G.; WOOD, A. The performance of insolvency prediction and credit risk models in the UK: A comparative study. **The British Accounting Review**, Vol. 45, Issue 3, p.183-202, 2013.

JAIKENGIT, A. Corporate Governance and Financial Distress: An Empirical Analysis – The Case of Thai Financial Institutions. **Western Reserve University**, Cleveland, OH, 2004.

JAN, A.; MARIMUTHU, M.; SHAD, M. K.; ZAHID, M.; JAN, A. A. Bankruptcy profile of the Islamic and conventional banks in Malaysia: a post-crisis period analysis. **Economic Change and Restructuring**, pp. 1-21, 2017.

JOHNSON, R. A.; WICHERN, D. W. Applied Multivariate Statistical Analysis. 6. ed. **Pearson Prentice Hall**, 2007.

KAPLIŃSKI, O. Usefulness and credibility of scoring methods in construction industry. **Journal of Civil Engineering and Management**, 14(1), p.21-28, 2010.

KASGARI, A. A.; DIVSALAR, M.; JAVID, M.R.; EBRAHIMIAN, S. J. Prediction of bankruptcy Iranian corporations through artificial neural network and Probit-based analyses. **Neural Computing & Applications**, 23(3-4), 927-936, 2013.

KHELIL, N. The many faces of entrepreneurial failure: Insights from an empirical taxonomy. **Journal of Business Venturing**, 31(1), p. 72-94, 2016.

KIM, J. Determinants and predictive powers of bankruptcy models for firms in Korea and the U.S. **Global Business & Finance Review**, Vol. 21, Issue 2, p.65-85, 2016.

KO, Y. C.; FUJITA, H.; LI, T. An evidential analysis of Altman Z-score for financial predictions: Case study on solar energy companies. **Applied Soft Computing Journal** 52, pp. 748-759, 2017.

KUBĚNKA, M.; MYŠKOVÁ, R. Obvious and Hidden Features of Corporate Default in Bankruptcy Models. **Journal of Business Economics and Management**, 20(2), p. 368–383, 2019.

KUMAR, P. R.; RAVI, V. Bankruptcy Prediction in Banks and Firms via Statistical and Intelligent Techniques – A Review. **European Journal of Operational Research** 180 p. 1-28, 2007.

KUMAR, G.; ROY, S. Development of Hybrid Boosting Technique for Bankruptcy Prediction. **International Conference on Information Technology**, 2016.

LEE, S.; KOH, Y.; KANG, K.H. Moderating effect of capital intensity on the relationship between leverage and financial distress in the U.S. restaurant industry. **International Journal of Hospitality Management**, Vol. 30, Issue 3, p. 429-438, 2011.

LEPETIT, L.; STROBEL, F. Bank insolvency risk and time-varying Z-score measures. **Journal of International Financial Markets, Institutions & Money**, Vol. 25, Issue C, p.73-87, 2013.

LEPETIT, L.; STROBEL, F. Bank insolvency risk and Z-score measures: A refinement. **Finance Research Letters**, Vol. 13, p. 214-224, 2015.

LI, L.; FAFF, R. Predicting corporate bankruptcy: What matters? **International Review of Economics & Finance**, 62, p. 1–19, 2019.

LI, M.Y.L.; MIL, P. A hybrid bankruptcy prediction model with dynamic loadings on accounting-ratio-based and market-based information: A binary quantile regression approach. **Journal of Empirical Finance**, Vol. 17, Issue 4, p. 818-833, 2010.

LIBBY, R. Accounting Ratios and the Prediction of Failure: Some Behavioral Evidence. **Journal of Accounting Research**, Spring, p. 150-161, 1975.

LIN, T. A Cross Model Study of Corporate Financial Distress Prediction in Taiwan: Multiple Discriminant Analysis, Logit, Probit and Neural Networks Models. **Neurocomputing**, Vol. 72, pp. 3507-3516, 2009.

LIOUS, N.A.T.; FELIX, P.G.; CIBRAN, M.A.C. The effectiveness of the Spanish banking reform application of Altman's Z-score. **Risk governance & control: financial markets & institutions**, Vol. 6, Issue 4, p 40-47, 2016.

LO, A. Logit Versus Discriminant Analysis, a Specification Test and Application to Corporate Bankruptcies. **Journal of Econometrics**, Vol. 31(2), pp. 151-78, 1986.

LU, C.; YANG, A. S.; HUANG, J. Bankruptcy Predictions for US Air Carrier Operations: A Study of Financial Data. **Journal Econ. Finance** 39 (3): 574–589, 2015.

MARION, J. C. Contabilidade Empresarial. 18ª ed., São Paulo: **Atlas**, 2018.

MENSAH, Y. An Examination of the Stationarity of Multivariate Bankruptcy Prediction Models: A Methodological Study. **Journal of Accounting Research**, p.380-395, 1984.

MONTGOMERY, D. C.; RUNGER, G. C. Estatística aplicada e probabilidade para engenheiros. 5ª ed., Rio de Janeiro: **LTC**, 2012.

MOODY, J. Moody's Transportation Manual. New York: **Mergent**, 1972-2002.

MORETTIN, P.A. & TOLOI, M C. Análise de Séries temporais, 2ª Ed. São Paulo: **Edgard Blucher**, 2006.

MSELMY, N., LAHIANI, A.; HAMZA, T. Financial distress prediction: the case of French small and medium-sized firms. **International Review of Financial Analysis**, 50 (1), p. 67-80, 2017.

NARESH, K. M.; SREE, H. R. V. A New Methodology for Estimating Internal Credit Risk and Bankruptcy Prediction under Basel II Regime. **Computational Economics Research**, Vol. 46, Issue 1, pp.83-102, 2015.

NGUYEN, T.P.T.; NGHIEM, S.H.; ROCA, E. Management Behaviour in Vietnamese Commercial Banks. **Australian Economic Papers**, Vol. 55, Issue 4, p. 345-367, 2017.

OBERMANN, L.; WAACK, S. Demonstrating Noninferiority of Easy Interpretable Methods for Insolvency Prediction. **Expert Systems with Applications**, 42 (23), p. 9117–9128, 2015.

ODOM, M.; SHARDA, R. A Neural Network for Bankruptcy Prediction. **International Conference on Neural Networks**, San Diego, CA, 1990.

OHLSON, J. A. Financial Ratios and the Probabilistic Prediction of Bankruptcy. **Journal of Accounting Research**, Vol. 18(1), pp. 109-131, 1980.

OMELKA, J.; BERANOVA, M.; TABAS, J. Comparison of the models of financial distress prediction. **Acta Universitatis Agriviculturae et Silviculturae Mendeliana Brunensis**, Vol. 61, No. 7, p. 2587-2592, 2013.

PAPANIKOLAOU, N. I. To be bailed out or to be left to fail? A dynamic competing risks hazard analysis. **Journal of Financial Stability**, 34, p. 61–85, 2018.

PEREIRA, V. S.; MARTINS, V. F. Estudos de Previsão de Falência – uma Revisão das Publicações Internacionais e Brasileiras de 1930 a 2015. **Revista Contemporânea de Contabilidade**, v. 12, n. 26, p. 163-196, 2015.

PHILOSOPHOV, L.V.; BATTEN, J.A.; PHILOSOPHOV, V.L. Predicting the event and time horizon of bankruptcy using financial ratios and the maturity schedule of long-term debt. **Mathematics and Financial Economics**, Vol. 1, Issue 3-4, p. 181-212, 2008.

PHILOSOPHOV, L.V.; PHILOSOPHOV, V.L. Corporate bankruptcy prognosis: An attempt at a combined prediction of the bankruptcy event and time interval of its occurrence. *International Review of Financial Analysis*, Vol. 11, Issue 3, p. 375-406, 2002.

PINCHES, G.; EUBANK, A.; MINGO, K.; CARUTHERS, J. The Hierarchical Classification of Financial Ratios. *Journal of Business Research*, nº 3, Vol. 4, pp. 295-310, 1975.

PITROVÁ, K. Possibilities of the Altman ZETA model application to Czech firms. *Ekonomika a Management*, Vol. 14, Issue 3, p. 66-76, 2011.

PLATT, H. D. Why Companies Fail: Strategies for Detecting Avoiding and Profiting from Bankruptcy. 2^a ed. Massachusetts: **Beard Books**, 1999.

POSTOLOV, K.; MILENKOVIC, I.; MILENKOVIC, D.; ILIEV, A.J. Influence of Market Values of Enterprise on Objectivity of the Altman Z-Model in the Period 2006-2012: Case of the Republic of Macedonia and Republic of Serbia. *Journal of Central Banking Theory and Practice*, Vol. 5(3), p 47-59, 2016.

RAZ, A.F. Risk and capital in Indonesian large banks. *Journal of Financial Economic Policy*, Vol. 10, Issue 1, pp. 165-184, 2018.

REŽŇÁKOVÁ, M.; KARAS, M. The prediction capabilities of bankruptcy models in a different environment: An example of the altman model under the conditions in the visegrad group countries. *Ekonomický casopis*, Vol. 63, Issue 6, p. 617-633, 2015.

RIBEIRO, B.; SILVA, C.; CHEN, N.; VIEIRA, A.; CARVALHO DAS NEVES, J. Enhanced Default Risk Models with SVM+. *Expert Systems with Applications*, 39 (11), p. 10140–10152, 2012.

SAIF, H.; AL ZAABI, O. Potential for the application of emerging market Z-score in UAE Islamic banks. *International Journal of Islamic and Middle Eastern Finance and Management*, Vol. 4, Issue 2, pp.158-173, 2011.

SALIMI, A.Y. Validity of altmans z-score model in predicting bankruptcy in recent years. *Academy of Accounting & Financial Studies Journal*, Vol. 19, No. 2, p. 233-238, 2015.

SHARMA, S.; MAHAJAN, V. Early warning indicators of business failure. *Journal of Marketing*, Vol. 44, pp. 80-89, 1980.

SHEPPARD, J. P. The Dilemma of Matched Pairs and Diversified Firms in Bankruptcy Prediction Models. *Mid-Atlantic Journal of Business*, Vol. 30, March, pp. 9-25, 1994.

SIMIĆ, D.; KOVAČEVIĆ, I.; SIMIĆ, S. Insolvency prediction for assessing corporate financial health. *Oxford University Press*, Vol. 20, Issue 3, p. 536-549, 2011.

SOLOSKI, J. Collapse of the US newspaper industry: Goodwill, leverage and bankruptcy. *Journalism*, Vol. 14(3), p. 309-329, 2013.

SOUSA, B. F. Geração de Séries Temporais Sintéticas de Vazões de Rios Considerando os Efeitos das Atividades Solares. Dissertação de Mestrado em Engenharia Elétrica: **Universidade Federal de Minas Gerais**, 2015.

TABACHNICK, B. G.; FIDELL, L. S. Using multivariate analysis. California State University Northridge: **Harper Collins College Publishers**, 2001.

TAN Y., ANCHOR J. Stability and profitability in the Chinese banking Industry: Evidence from an auto-regressive-distributed linear specification. **Investment Management and Financial Innovations**, Volume 13, Issue 4, 2016.

TANG, Y.; JI, J.; ZHU, Y.; GAO, S.; TANG, Z.; TODO, Y. A Differential Evolution-Oriented Pruning Neural Network Model for Bankruptcy Prediction. **Complexity**, 1, p. 1-21, 2019.

TAY, F. E. H.; SHEN, L. Economic and Financial Prediction Using Rough Set Model. **European Journal of Operational Research** 141, p. 641-659, 2002.

THOMAS, Ng S.; WONG, J.M.W.; ZHANG, J. Applying Z-score model to distinguish insolvent construction companies in China. **Habitat International**, Vol. 35(4), p. 599-607, 2011.

TIAN, S.; YU, Y. Financial ratios and bankruptcy predictions: An international evidence. **International Review of Economics and Finance**, Vol. 51(C), p. 510-526, 2017.

TRABELSI, M.A.; TRAD, N. Profitability and risk in interest-free banking industries: a dynamic panel data analysis. **International Journal of Islamic and Middle Eastern Finance and Management**, Vol. 4, Issue 4, p. 454-469, 2017.

TRAD, N.; TRABELSI, M.A.; GOUX, J.F. Risk and profitability of Islamic banks: A religious deception or an alternative solution? **European Research on Management and Business Economics**, Vol. 23, Issue 1, p. 40-45, 2017.

VAZIRI, M.; BHUYAN, R.; MANUEL, P.A.V. Comparative predictability of failure of financial institutions using multiple models. **Investment Management and Financial Innovations**, Vol. 9, Issue 2, p. 120-127, 2012.

VAVŘINA, J.; HAMPEL, D.; JANOVÁ, J. New approaches for the financial distress classification in agribusiness. **Acta Universitatis Agriviculturae et Silviculturae Mendeliana Brunensis**, Vol. 61, No. 4, p. 1177-1182, 2013.

WARDAYANTI, A.; SUTOPO, W.; HISJAM, M.; RASLI, A. Bankruptcy prediction using altman z-score model and 5w+1h approach to elaborate strategy. **Advanced Science Letters**, 23 (9). pp. 8664-8667, 2017.

XU, M.; ZHANG, C. Bankruptcy prediction: The case of Japanese listed companies. **Review of Accounting Studies**, Vol. 14, Issue 4, p. 534-558, 2009.

YU, Q.; MICHE, Y.; SEVERIN, E.; LENDASSE, A. Bankruptcy Prediction Using Extreme Learning Machine and Financial Expertise. **Neurocomputing**, Vol. 128 No. 128, pp. 296-302, 2014.

ZHANG, L.; ALTMAN, E.I., YEN, J. Corporate financial distress diagnosis model and application in credit rating for listing firms in China. **Frontiers of Computer Science in China**, Vol. 4, Issue 2, p. 220-236, 2010.

ZMIJEWSKI, M. Methodological Issues Related to the Estimation of Financial Distress Prediction Models. **Journal of Accounting Research**, Vol. 22, 1984.

APÊNDICE 1 – LISTA COMPLETA DE VARIÁVEIS

Tabela 1 – Lista Completa de Variáveis com Aparições no Grupo 2 da Revisão de Literatura

Variável	Aparições
ROA = Net returns/Total assets	(HALTEH <i>et al.</i> , 2018); (IM <i>et al.</i> , 2018); (TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017); (BOD'A e ÚRADNÍČEK, 2016); (BURGANOVA e SALAHIEVA, 2015); (THOMAS <i>et al.</i> , 2011)
ROE = Net returns/Equity	(IM <i>et al.</i> , 2018); (BARBOZA <i>et al.</i> , 2017); (TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
Net loans/Total assets	(GAVUROVÁ <i>et al.</i> , 2017); (TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
Total assets	(IM <i>et al.</i> , 2018); (BARBOZA <i>et al.</i> , 2017); (KARAS e REZNAKOVA, 2014)
Total Debt/Total Asset	(IM <i>et al.</i> , 2018); (GRDIC <i>et al.</i> , 2017); (LEE <i>et al.</i> , 2011)
Current liabilities/Total assets	(IM <i>et al.</i> , 2018); (CHARALAMBAKIS e GARRETT, 2016); (PHILOSOPHOV e PHILOSOPHOV, 2002)
Total debt/Equity	(TIAN e YU, 2017); (GRDIC <i>et al.</i> , 2017); (LEE <i>et al.</i> , 2011)
Total equity/net loans	(TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
Impaired loans/gross loans	(TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
Napierian logarithm of total assets for each bank	(TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
Capital/total assets	(TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
Loan loss provision/net interest income	(TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
Loan loss reserves/gross loans	(TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
GDP growth rate (%)	(TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
Inflation rate (en %)	(TRAD <i>et al.</i> , 2017); (TRABELSI e TRAD, 2017)
Net income/Total revenue	(HALTEH <i>et al.</i> , 2018); (BURGANOVA e SALAHIEVA, 2015)
Growth in sales	(IM <i>et al.</i> , 2018); (BARBOZA <i>et al.</i> , 2017)
Growth in the number of employees	(IM <i>et al.</i> , 2018); (BARBOZA <i>et al.</i> , 2017)
Operational margin	(IM <i>et al.</i> , 2018); (BARBOZA <i>et al.</i> , 2017)
Chance in price-to-book ratio	(IM <i>et al.</i> , 2018); (BARBOZA <i>et al.</i> , 2017)
Profit/Turnover	(PITROVÁ, 2011); (LEE <i>et al.</i> , 2011)
Current assets/Current liabilities	(THOMAS <i>et al.</i> , 2011); (APPIAH e ABOR, 2009)
Interest payments/Total assets	(PHILOSOPHOV <i>et al.</i> , 2008); (PHILOSOPHOV e PHILOSOPHOV, 2002)
Net Loans/deposits and short-term financing rate	(TRABELSI e TRAD, 2017)
Oficial exchange rate	(TRAD <i>et al.</i> , 2017)
Profit before tax/Current liabilities	(CHARALAMBAKIS e GARRETT, 2016)
Current assets/Total liabilities	(CHARALAMBAKIS e GARRETT, 2016)
Quickassets-currentliabilities/(Sales-profitbeforetax-depreciation)	(CHARALAMBAKIS e GARRETT, 2016)
Current Liability/Sales	(TIAN e YU, 2017)
Equity/Total Liability	(TIAN e YU, 2017)
Annual average growth rate of quick liquidity coefficient	(BURGANOVA e SALAHIEVA, 2015)
Annual average growth rate of borrowed and internal funds correlation coefficient.	(BURGANOVA e SALAHIEVA, 2015)
Annual average growth rate of assets turnover coefficient.	(BURGANOVA e SALAHIEVA, 2015)
Assets/Equity	(GAVUROVÁ <i>et al.</i> , 2017)
Cash Flow/Loan Capital	(GAVUROVÁ <i>et al.</i> , 2017)
Financial Assets/Current Liabilities	(GAVUROVÁ <i>et al.</i> , 2017)
Liquid assets/Total assets	(TRAD <i>et al.</i> , 2017)
Liquid assets/Deposits and short-term financing rate	(TRAD <i>et al.</i> , 2017)
Loan loss reverses/Impaired loans	(TRAD <i>et al.</i> , 2017)
(Current assets – Inventories) / Current liabilities	(KARAS e REZNAKOVA, 2014)
Net sales/Net property, Plant and equipment	(LEE <i>et al.</i> , 2011)
Size measured by log of revenue	(LEE <i>et al.</i> , 2011)
Total market value/Total assets	(LEE <i>et al.</i> , 2011)
Unemployment rate	(LEE <i>et al.</i> , 2011)
Earnings before tax and interest/Interest expenses	(THOMAS <i>et al.</i> , 2011)
Net value of sales/Average current asset.	(THOMAS <i>et al.</i> , 2011)
Total Assets - Current Liabilities	(APPIAH e ABOR, 2009)
Average debtors collection period	(APPIAH e ABOR, 2009)
Profit before interest and tax/shareholders equity	(APPIAH e ABOR, 2009)
Income gearing	(APPIAH e ABOR, 2009)

Fonte: Autor (2020)