



Universidade de Brasília (UnB)  
Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas  
(FACE)  
Departamento de Ciências Contábeis e Atuariais (CCA)  
Programa de Pós-Graduação em Ciências Contábeis (PPGCont)

ELMO DIAS DA SILVEIRA

**ENSAIOS SOBRE INTELIGÊNCIA ARTIFICIAL E A PRÁTICA DE  
GERENCIAMENTO DE RESULTADOS**

Brasília  
2023

Professora Doutora Márcia Abrahão Moura  
**Reitora da Universidade de Brasília**

Professor Doutor Enrique Huelva Unternbäumen  
**Vice-Reitor da Universidade de Brasília**

Professor Dr. Lúcio Remuzat Rennó Junior  
**Decano de Pós-Graduação**

Professor Dr. José Márcio Carvalho  
**Diretor da Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas  
Públicas**

Professor Dr. Sérgio Ricardo Miranda Nazaré  
**Chefe do Departamento de Ciências Contábeis e Atuariais**

Professor Dr. Jomar Miranda Rodrigues  
**Coordenador do Programa Pós-Graduação em Ciências Contábeis**

ELMO DIAS DA SILVEIRA

ENSAIOS SOBRE INTELIGÊNCIA ARTIFICIAL E A PRÁTICA DE GERENCIAMENTO  
DE RESULTADOS

Tese submetida ao Programa de Pós-Graduação em Ciências Contábeis, do Departamento de Ciências Contábeis e Atuariais, da Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas, da Universidade de Brasília.

BANCA EXAMINADORA:

---

Prof. Paulo Augusto Pettenuzzo de Britto, Ph.D.  
Universidade de Brasília  
Orientador

---

Prof. Dr. Luiz Paulo Lopes Fávero  
Universidade de São Paulo  
Examinador Externo

---

Prof. Dr. Fábio Moraes da Costa  
*FUCAPE Business School*  
Examinador Externo

---

Prof. Dr. Marcelo Driemeyer Wilbert  
Universidade de Brasília  
Examinador Interno

---

Prof. Dr. Rodrigo de Souza Gonçalves  
Universidade de Brasília  
Suplente

De DIAS DA SILVEIRA, ELMO  
ENSAIOS SOBRE INTELIGÊNCIA ARTIFICIAL E A PRÁTICA DE  
GERENCIAMENTO DE RESULTADOS / ELMO DIAS DA SILVEIRA;  
orientador Paulo Augusto Pettenuzzo de Britto. -- Brasília,  
2023.  
89 p.

Tese(Doutorado em Ciências Contábeis) -- Universidade de  
Brasília, 2023.

1. Inteligência Artificial. 2. Machine Learning. 3.  
Gerenciamento de Resultados. 4. Accruals. 5. Redes Neurais  
Artificiais. I. Augusto Pettenuzzo de Britto, Paulo, orient.  
II. Título.

*Aos meus irmãos, meu pai e minha mãe (in memoriam).*

## AGRADECIMENTOS

Primeiramente, sou grato a Deus em todas as suas manifestações em minha vida, por todos os ensinamentos que pude absorver e pelos que ainda virão.

Aos meus pais, manifestações da presença de Deus que mais se aproximam da natureza pura de Seu amor, agradeço pelo privilégio que representa suas presenças em minha existência e dedico todos os meus esforços e conquistas.

Agradeço aos meus irmãos Fausto, Gabrielle, Fernanda e Flávio, demais familiares e amigos por cada experiência compartilhada, cada afeto demonstrado. A empatia, o carinho e o companheirismo são constantes, mas nos marcam mais profundamente em momentos difíceis. O apoio e o carinho de vocês foram imprescindíveis em diversas destas ocasiões, em especial.

Agradeço imensamente a todos os professores com os quais tive a oportunidade de conviver e aprender, verdadeiros guias que moldaram o melhor de mim para enfrentar os desafios que me aguardavam. Dentre estes, agradeço especialmente ao professor Ercílio Zanolla, professor na graduação (UFG) e orientador na especialização, com o qual tive a felicidade de publicar meu primeiro artigo, juntamente com o professor Lúcio. Ao professor Carlos Henrique, agradeço por todos os ensinamentos em sala de aula e, muito mais, por seus ensinamentos que emanam naturalmente de sua postura inspiradora, além de ser uma fonte de energia contagiante e inesgotável.

Desde o início de minha jornada pela Universidade de Brasília, pude experimentar diversos momentos marcantes. Tais momentos se devem a todos os professores, servidores e voluntários daquela universidade que me acolheu sempre, da melhor forma que poderia. Portanto, agradeço à paciência e disposição da Inez e da Sara, assim como de todos os servidores do PPGCont/UnB. Aos professores do departamento, me sinto imensamente grato pelas experiências e ensinamentos, assim como pela paciência e prontidão ao lidar com nossas dúvidas. Agradeço especialmente aos professores Otávio Medeiros, Paulo Lustosa, César Augusto, Jorge Katsumi, Rodrigo Gonçalves, Jomar Rodrigues e Mariana Guerra. Dedico um espaço para homenagear meu orientador no mestrado, professor José Alves Dantas, que representa tanto para mim e sempre terei muito orgulho de ter sido seu orientando. Agradeço profundamente ao meu orientador nesta etapa, professor Paulo Augusto Pettenuzzo de Britto, por todo seu esforço e dedicação em sua tarefa.

Em minha passagem pela UnB, conheci pessoas incríveis, com as quais experimentei momentos que marcaram minha vida profundamente. Meus colegas de turma Tiago Mota, Rafael Lima, Victor Godeiro, Kleber Vasconcellos e, especialmente, Paulo Vitor, que com certeza sabe da grandeza de nossos momentos juntos, mesmo os mais “triviais”. Agradeço imensamente cada um deles, pois são dádivas que o doutorado me deu. Deixo um agradecimento especial ao grande amigo Iuri, sempre presente quando mais precisei.

*Há na vida momentos privilegiados em que parece que o universo se ilumina, que a nossa vida nos revela sua significação, que queremos o destino mesmo que nos coube, como se nós mesmos o tivéssemos escolhido. Depois o universo volta a fechar-se, tornamo-nos novamente solitários e miseráveis, já não caminhamos, senão tateando num caminho obscuro onde tudo se torna obstáculo aos nossos passos. A sabedoria consiste em salvaguardar a lembrança desses momentos fugidios, em saber fazê-los reviver e fazer deles a trama da nossa existência cotidiana e, por assim dizer, a morada habitual do nosso espírito.*

*Louis Lavelle*

ELMO DIAS DA SILVEIRA

ENSAIOS SOBRE INTELIGÊNCIA ARTIFICIAL E A PRÁTICA DE GERENCIAMENTO  
DE RESULTADOS

Tese submetida ao Programa de Pós-Graduação em Ciências Contábeis, do Departamento de Ciências Contábeis e Atuariais, da Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas, da Universidade de Brasília.

Orientador: Prof. Paulo Augusto Pettenuzzo de Britto, Ph.D.

Área: Mensuração Contábil.

Linha de Pesquisa: Contabilidade e Mercado Financeiro.

Brasília

2023



## RESUMO

Esta tese consiste em uma investigação sobre o gerenciamento de resultados, centrada na avaliação e aprimoramento de modelos tradicionais de detecção de gerenciamento de resultados por meio de abordagens inovadoras. O primeiro artigo, um ensaio teórico, destaca a Rede Neural Artificial (RNA) como uma ferramenta promissora para resolver problemas econométricos associados aos modelos tradicionais de detecção de gerenciamento de resultados por *accruals*. A pesquisa aborda questões relacionadas à falta de verificabilidade direta dos *accruals* discricionários e argumenta que a aplicação da RNA pode melhorar significativamente o poder e a especificidade desses modelos. O segundo artigo, de natureza empírica, concentra-se na reversão de distorções em *accruals* e sua aplicação em modelos tradicionais de gerenciamento de resultados em empresas brasileiras de capital aberto. Os resultados revelam as limitações dos modelos baseados em *accruals*, destacando a complexidade dos *accruals* não discricionários e os desafios associados à mensuração precisa do gerenciamento. O terceiro artigo, também empírico, explora o uso de técnicas de *machine learning* na detecção de gerenciamento de resultados. O estudo visa explorar metodologias que superem as deficiências dos modelos tradicionais, especialmente no que diz respeito à mensuração precisa do gerenciamento de resultados. Os resultados indicam que algoritmos de *machine learning*, como o *Decision Trees Classifier*, oferecem uma solução viável para aumentar significativamente o poder explicativo desses modelos. De forma geral, esta tese pretende contribuir para a compreensão da prática de gerenciamento de resultados e aprimoramento das ferramentas que objetivam detectar a ocorrência de tais práticas, destacando a importância de abordagens inovadoras, como RNA e *machine learning*, na resolução de desafios persistentes em modelos tradicionais. Essas descobertas promovem uma melhor integração entre a contabilidade e a tecnologia da informação, abrindo caminho para futuras pesquisas que explorem uma variedade de técnicas de inteligência artificial visando melhorias na qualidade da informação contábil.

Palavras-chave: Inteligência Artificial; *Machine Learning*; Gerenciamento de Resultados; *Accruals*; Redes Neurais Artificiais.

## **ABSTRACT**

This thesis consists of an investigation into earnings management, focused on the evaluation and improvement of traditional earnings management detection models through innovative approaches. The first article, a theoretical essay, highlights the Artificial Neural Network (ANN) as a promising tool for solving econometric problems associated with traditional earnings management detection models through accruals. The research addresses issues related to the lack of direct verifiability of discretionary accruals and argues that the application of ANN can significantly improve the power and specificity of these models. The second article, empirical in nature, focuses on the reversal of distortions in accruals and its application in traditional earnings management models in publicly traded Brazilian companies. The results reveal the limitations of accrual-based models, highlighting the complexity of non-discretionary accruals and the challenges associated with accurate management measurement. The third article, also empirical, explores the use of machine learning techniques in detecting earnings management. The study aims to explore methodologies that overcome the deficiencies of traditional models, especially regarding the precise measurement of earnings management. The results indicate that machine learning algorithms, such as the Decision Trees Classifier, offer a viable solution to significantly increase the explanatory power of these models. In general, this thesis aims to contribute to the understanding of the practice of earnings management and improvement of tools that aim to detect the occurrence of such practices, highlighting the importance of innovative approaches, such as ANN and machine learning, in resolving persistent challenges in traditional models. These findings promote better integration between accounting and information technology, paving the way for future research that explores a variety of artificial intelligence techniques aimed at improving the quality of accounting information.

**Keywords:** Artificial intelligence; Machine Learning; Earnings Management; Accruals; Artificial neural networks.

## LISTA DE ILUSTRAÇÕES

|  |    |
|--|----|
| <b>Figura 1:</b> Ramos de aplicação da Inteligência Artificial.....  | 22 |
| <b>Figura 2:</b> Campos da Inteligência Artificial.....  | 23 |
| <b>Figura 3:</b> Programação Clássica vs Machine Learning.....   | 23 |
| <b>Figura 4:</b> Esquema matemático de um Neurônio Artificial.....   | 24 |
| <b>Figura 5:</b> Neurônio biológico vs neurônio artificial.....  | 25 |
| <b>Figura 6:</b> Gerenciamento induzido equivalente a 1% da Variação dos Ativos Totais.....                | 45 |
| <b>Figura 7:</b> Gerenciamento induzido equivalente a 2% da Variação dos Ativos Totais.....                | 46 |
| <b>Figura 8:</b> Frequência de Rejeição de Ausência de Gerenciamento em Relação ao Tamanho da Amostra..... | 47 |
| <b>Figura 9:</b> Matriz de Confusão para Decision Trees com simulações de 1% para 40% da amostra.....      | 71 |
| <b>Figura 10:</b> Resultados do treinamento do Decision Trees para cada rótulo (label).....                | 72 |

**LISTA DE QUADROS**

|  |    |
|--|----|
| <b>Quadro 1:</b> Algoritmos de <i>Machine Learning</i> utilizados. ....                  | 60 |
| <b>Quadro 2:</b> Labels para treinamento dos algoritmos de <i>machine learning</i> ..... | 61 |
| <b>Quadro 3:</b> <i>Labels</i> e respectivos valores para <i>dummies</i> .....           | 64 |

## LISTA DE TABELAS

|  |    |
|--|----|
| <b>Tabela 1:</b> Estatísticas descritivas das variáveis dependentes. ....  | 40 |
| <b>Tabela 2:</b> Estatísticas descritivas da variável independente. ....   | 40 |
| <b>Tabela 3:</b> Estatísticas descritivas dos <i>accruals</i> de capital de giro para decis formados no desempenho dos lucros. ....                    | 41 |
| <b>Tabela 4:</b> Média dos coeficientes, estatística <i>t</i> e <i>R</i> -quadrado ajustado dos modelos. ....  | 42 |
| <b>Tabela 5:</b> percentual de rejeição das hipóteses estatísticas após mil regressões. ....   | 43 |
| <b>Tabela 6:</b> Estatísticas descritivas das variáveis dependentes dos modelos testados na pesquisa. ....   | 68 |
| <b>Tabela 7:</b> Estatísticas descritivas da variável independente dos modelos testados na pesquisa. ....  | 68 |
| <b>Tabela 8:</b> Resultados do treinamento dos algoritmos de machine learning. ....  | 69 |
| <b>Tabela 9:</b> Médias dos coeficientes e suas estatísticas <i>t</i> e <i>R</i> -quadrado ajustado para o cenário de 0,1% de eventos. ....            | 74 |
| <b>Tabela 10:</b> Médias dos coeficientes e suas estatísticas <i>t</i> e <i>R</i> -quadrado ajustado para o cenário de 20% de eventos. ....            | 76 |
| <b>Tabela 11:</b> Médias dos coeficientes e estatísticas <i>t</i> e <i>R</i> -quadrado ajustado dos Modelos Gerais no cenário de 0,1% de eventos. .... | 78 |
| <b>Tabela 12:</b> Médias dos coeficientes e estatísticas <i>t</i> e <i>R</i> -quadrado ajustado dos Modelos Gerais no cenário de 20% de eventos. ....  | 80 |

## SUMÁRIO

|  |    |
|--|----|
| 1. INTRODUÇÃO .....  | 15 |
| 2. Ensaio Teórico sobre o uso das Redes Neurais Artificiais no Gerenciamento de Resultados.....                                  | 17 |
| 2.1. Introdução .....  | 18 |
| 2.2. Corpo do Ensaio Teórico .....   | 20 |
| 2.2.1. Gerenciamento de Resultados por <i>Accruals</i> .....   | 20 |
| 2.2.2. Problemas Econométricos em Modelos de Gerenciamento por <i>Accruals</i> .....   | 21 |
| 2.2.3. Inteligência Artificial, <i>Machine Learning</i> e Redes Neurais Artificiais .....  | 22 |
| 2.2.4. Redes Neurais Artificiais e Gerenciamento por <i>Accruals</i> .....   | 25 |
| 2.3. Considerações Finais .....  | 27 |
| Referências.....   | 29 |
| 3. Detecção de Gerenciamento de Resultados com Base em Simulações Utilizando a Abordagem de Reversões de <i>Accruals</i> . ..... | 32 |
| 3.1. Introdução .....  | 33 |
| 3.2. Referencial .....   | 34 |
| 3.2.1. Modelos de Detecção de Gerenciamento de Resultados.....   | 34 |
| 3.3. Metodologia .....   | 36 |
| 3.3.1. Amostra .....   | 36 |
| 3.3.2. Modelos Utilizados no Trabalho .....  | 36 |
| 3.3.3. Procedimentos Metodológicos .....   | 38 |
| 3.3.4. Etapas para o Contexto 1 .....  | 38 |
| 3.3.5. Etapas para o Contexto 2 .....  | 38 |
| 3.4. Análise dos Resultados .....  | 40 |
| 3.4.1. Estatísticas Descritivas .....  | 40 |
| 3.5. Resultados dos Testes .....   | 42 |
| 3.5.2. Poder dos Testes para Gerenciamento de Resultados Usando Simulações com Gerenciamento Induzido .....                      | 44 |
| 3.6. Considerações Finais .....  | 49 |
| Referências.....   | 50 |
| 4. Explorando o Potencial das Técnicas de <i>Machine Learning</i> na Detecção de Gerenciamento de Resultados .....               | 52 |
| 4.1. Introdução .....  | 53 |
| 4.2. Referencial .....   | 54 |
| 4.2.1. Problemas do Teste Conjunto de Hipóteses .....  | 54 |

|        |  |    |
|--------|--|----|
| 4.2.2. | Eficiência de Mercado vs Qualidade dos Lucros .....                            | 55 |
| 4.3.   | Metodologia .....  | 59 |
| 4.3.1. | Amostra .....  | 60 |
| 4.4.   | Treinamento dos Algoritmos de <i>Machine Learning</i> .....                    | 60 |
| 4.5.   | Modelos Utilizados nos Testes com Regressões .....                             | 62 |
| 4.5.1. | Estrutura do Modelo Geral .....  | 63 |
| 4.5.2. | Modelos Base .....   | 63 |
| 4.6.   | Etapas para Regressões Utilizando Simulações.....                              | 66 |
| 4.7.   | Resultados .....   | 68 |
| 4.7.1. | Estatísticas Descritivas .....   | 68 |
| 4.8.   | Resultados do Treinamento dos Algoritmos de <i>Machine Learning</i> .....      | 69 |
| 4.8.1. | Resultados Gerais do Treinamento.....  | 69 |
| 4.8.2. | Desempenho do <i>Decision Tree Classifier</i> por Classe ( <i>Label</i> )..... | 70 |
| 4.9.   | Resultados do Testes Utilizando Regressões .....                               | 73 |
| 4.9.1. | Resultados do Testes Utilizando os Modelos Base .....                          | 73 |
| 4.9.2. | Resultados do Testes Utilizando os Modelos Gerais .....                        | 77 |
| 4.10.  | Considerações Finais .....   | 82 |
|        | Referências .....  | 84 |
| 5.     | Considerações Finais.....  | 88 |

## 1. INTRODUÇÃO

O presente trabalho se insere em um contexto no qual, segundo Fama (1980), economistas há muito se preocupam: problemas de incentivos que surgem quando a tomada de decisões numa empresa é da competência de gestores que não são os detentores dos títulos da empresa. Exemplos desta preocupação podem ser encontrados desde, ao menos, *The Wealth of Nations*, de Adam Smith (1776). Porém, conforme Fama (1980), a literatura moderna sobre o tema pode ser traçada a partir de Berle e Means (1932).

Uma das consequências da busca por um entendimento mais preciso dos problemas de incentivos foi o desenvolvimento de teorias “comportamentais” e “gerenciais” da firma, as quais rejeitam o modelo clássico de empresário, ou proprietário-administrador, agindo obstinadamente para maximizar seus lucros. As teorias “comportamentais” focam nas motivações dos administradores que controlam, mas não têm a propriedade e tem pouca semelhança com o clássico “homem econômico” (Fama, 1980).

Posteriormente, a literatura avançou para teorias que rejeitam o modelo clássico da empresa, mas assumem formas clássicas de comportamento econômico por parte dos agentes dentro da empresa. A empresa é vista como um conjunto de contratos entre fatores de produção, com cada fator motivado pelo seu interesse próprio. Por enfatizar a importância dos direitos na organização estabelecida pelos contratos, esta literatura é caracterizada sob a rubrica “direitos de propriedade”. Alchian e Demsetz (1972) e Jensen e Meckling (1976) são exemplos. Os antecedentes de seu trabalho estão em Coase (1937, 1960).

Segundo Subramaniam (2006), a Teoria da Agência tem suas raízes na literatura da economia da informação. Para Eisenhardt (1989), esta teoria aumentou o escopo da literatura que tratava nos problemas advindos do compartilhamento de riscos entre indivíduos ou grupos (como, por exemplo, Arrow (1971) e Wilson (1968)), incluindo o que se definiu como problemas de agência, os quais ocorrem quando partes colaboradoras possuem diferentes objetivos e diferentes visões sobre suas relações.

A relação entre gestores e acionistas tem sido objeto de profunda reflexão no campo da Teoria da Agência, onde a preocupação com a assimetria de informações e a possibilidade da ocorrência de gerenciamento de resultados ganham destaque. A literatura contábil e financeira tem se dedicado extensivamente a investigar as práticas de manipulação de dados contábeis e a demarcação entre *accruals* “normais” e “anormais”. Este tema intrincado se desdobra em três artigos que exploram diferentes aspectos dessas questões.

O primeiro artigo é estruturado em forma de ensaio teórico e foca na essência da teoria da agência, destacando a tensão inerente entre os interesses do principal e do agente. A assimetria informacional, causada pela separação entre controle e propriedade, propicia espaço para práticas oportunistas de gerenciamento de resultados. Tradicionalmente, modelos que se baseiam na distinção entre *accruals* discricionários e não discricionários são adotados para detectar tais práticas. No entanto, esses modelos enfrentam desafios metodológicos significativos, como a não linearidade do processo de *accruals*.

Para superar essas limitações, o ensaio propõe uma abordagem inovadora: o uso de Redes Neurais Artificiais (RNA). A inteligência artificial, com sua capacidade de aprender com dados e simular padrões complexos, surge como uma solução promissora. As RNAs, em particular, demonstram adaptabilidade e eficácia na detecção de padrões subjacentes em dados contábeis. Ao explorar a aplicação de RNAs na identificação de *accruals* discricionários, o estudo oferece uma perspectiva inovadora para mitigar os problemas de agência e melhorar a qualidade da informação contábil.



O segundo artigo é empírico e centra-se na complexidade de distinguir entre *accruals* "normais" e "anormais". Esta distinção é crucial para entender o gerenciamento de resultados e suas implicações nos relatórios financeiros. No entanto, modelos tradicionais baseados em abordagens lineares muitas vezes não capturam a verdadeira natureza não linear do processo de *accruals*. Além disso, a introdução de técnicas como o *matching* com base no desempenho traz consigo desafios empíricos significativos.

Uma característica fundamental do processo baseado em *accruals*, é que as distorções de geradas em um período devem ser revertidas em outro período subsequente. No caso de *accruals* de capital de giro, que normalmente duram menos de um ano, tais reversões geralmente ocorrem dentro de um ano ou mais a partir do evento original. Baseado nesta premissa, este segundo trabalho utilizou a estrutura metodológica proposta por Dechow et al. (2012) para testar se esta é capaz de introduzir melhorias em termos de poder e especificidade dos modelos tradicionais de gerenciamento de resultados no contexto das empresas brasileiras de capital aberto.

O terceiro artigo é, também, de caráter empírico e busca ampliar o escopo da investigação. Abordando a mesma problemática da distinção entre *accruals* "normais" e "anormais", o estudo considera as limitações dos modelos tradicionais e questiona a viabilidade de soluções inovadoras.

Este terceiro trabalho adota uma abordagem transformadora, incorporando algoritmos de *machine learning* para identificar períodos de manipulação de *accruals* e suas reversões. Ao fazê-lo, a pesquisa não apenas expande o entendimento sobre o gerenciamento de resultados em cenários específicos (com a utilização de simulações), mas também lança luz sobre o potencial revolucionário das técnicas de *machine learning* na análise contábil.

Esses três artigos, cada um focado em uma faceta única do gerenciamento de resultados, formam um corpo coeso de pesquisa que não apenas explora os desafios inerentes à teoria da agência e à assimetria informacional, mas também propõe soluções inovadoras baseadas em inteligência artificial e *machine learning*. Juntos, esses estudos buscam contribuir significativamente para as discussões na área contábil, oferecendo *insights* para pesquisadores, profissionais e tomadores de decisão. Ao unir teoria e prática, esses trabalhos oferecem uma visão abrangente e aprofundada sobre uma questão central no mundo dos negócios contemporâneo: a confiabilidade dos relatórios financeiros em um cenário de complexidades crescentes.

## 2. Ensaio Teórico sobre o uso das Redes Neurais Artificiais no Gerenciamento de Resultados

### *Theoretical Essay on the use of Artificial Neural Networks in Earnings Management*

#### **Resumo**

A Rede Neural Artificial (RNA) tem capacidade de simular uma rede neural biológica e apresenta-se como uma ferramenta que pode auxiliar na redução de problemas econométricos mediante modelos matemáticos. Modelos de gerenciamento de resultados apresentam um problema fundamental pelo fato dos *accruals* discricionários da gestão não serem diretamente observáveis, o que vem a afetar a avaliação do desempenho real de empresas. Portanto, este ensaio tem como objetivo apresentar a RNA como uma abordagem que pode minimizar problemas observados em modelos de gerenciamento de resultados por *accruals*. A literatura sobre gerenciamento de resultados apresenta diversos problemas relacionados aos modelos por *accruals*: *proxies* não confiáveis, interpretação restrita, incentivos, existência de condições simultâneas, problemas de correlação, classificação e especificação em modelos de gerenciamento, entre outros. Com base no suporte teórico apresentado pela literatura, entende-se que a utilização da abordagem da RNA pode proporcionar melhores níveis de poder e especificidade em modelos de gerenciamento de resultados por *accruals*. Este estudo visa contribuir com diversos usuários da informação contábil por evidenciar problemas em modelos de gerenciamento, bem como apresentar uma proposta baseada em inteligência artificial como solução para os problemas observados.

**Palavras-chave:** Gerenciamento de Resultados. *Accruals*. Redes Neurais Artificiais. *Machine Learning*.

#### **Abstract**

*The Artificial Neural Network (ANN) is capable of simulating a biological neural network and is presented as a tool that can help reduce econometric problems through mathematical models. Earnings management models present a fundamental problem due to the fact that management's discretionary accruals are not directly observable, which affects the evaluation of the real performance of companies. Therefore, this essay aims to present ANN as an approach that can minimize problems observed in accrual earnings management models. The literature on earnings management presents several problems related to accruals models: unreliable proxies, restricted interpretation, incentives, existence of simultaneous conditions, correlation problems, classification and specification in management models, among others. Based on the theoretical support presented by the literature, it is understood that the use of the ANN approach can provide better levels of power and specificity in accrual earnings management models. This study aims to contribute to several users of accounting information by highlighting problems in management models, as well as presenting a proposal based on artificial intelligence as a solution to the observed problems.*

**Keywords:** *Earnings Management. Accruals. Artificial Neural Networks. Machine Learning.*

## 2.1.Introdução

Quando o processo de tomada de decisões em uma empresa é atribuído a um gestor, preocupações sobre a presença de incentivos na geração de informações são recorrentes. Fama (1980) destaca que ao longo de muito tempo economistas têm se preocupado com a presença de incentivos na tomada de decisões de gestores, pois a informação gerada por estes pode não condizer com a melhor realidade das empresas.

A existência de problemas entre os participantes em um contrato originou a relação entre principal e agente. A teoria da agência determina que uma organização é concebida por uma rede de contratos, e nessa rede surge as figuras do principal e agente, mediante a ideia de que um agente é contratado pelo principal para agir de acordo com seus interesses. Porém, a relação de agência apresenta um problema, pois tanto o agente, quanto o principal buscam maximizar suas próprias utilidades e nem sempre os interesses de ambos estão alinhados (Berle & Means, 1932; Jensen & Meckling, 1976).

Os problemas da relação entre principal e agente são advindos principalmente da separação entre controle e propriedade, o que acaba resultando em limitações do principal em observar as ações dos agentes, gerando assim uma margem para que estes agentes atuem em desacordo com os interesses do principal (Subramaniam, 2006). Assim, surge a assimetria informacional, que consiste em informações em níveis diferenciados para ambas as partes de um contrato. No entanto, essa assimetria surge pelo fato de o agente ter acesso a dados que o principal não possui, o que acaba gerando uma maior possibilidade desse agente maximizar seus próprios interesses em prol dos interesses do principal (Jensen & Meckling, 1976).

Mediante o exposto, a informação contábil age como uma ferramenta que visa minimizar a assimetria de informações, e conseqüentemente os problemas de agência. Segundo Black e Nakao (2017), o processo de adoção de normas internacionais de contabilidade teve como principal objetivo melhorar a qualidade da informação fornecida pelos relatórios financeiros e demonstrações contábeis. Entende-se, portanto, que a informação contábil é de fundamental importância para a redução da assimetria informacional.

Neste contexto, relatórios financeiros de qualidade são fundamentais e observar se a informação contábil é influenciada pela gestão torna-se importante para atestar a qualidade dos lucros gerados. Assim, conforme literatura, notou-se que gestores têm se utilizado de práticas de gerenciamento de resultados (Scott, 2015). Para Healy e Wahlen (1999), os gestores utilizam julgamentos que criam oportunidades para que os resultados das entidades sejam gerenciados, mediante a escolha de métodos contábeis que não reflitam com precisão os fenômenos de uma empresa, distorcendo assim a informação fornecida pela contabilidade. Portanto, nota-se que a prática do gerenciamento de resultados afeta negativamente a qualidade da informação (Salgado & Souza, 2021), o que pode vir a interferir no aumento da assimetria informacional e na maximização da utilidade de somente uma parte em um contrato de agência.

Uma parte considerável das pesquisas sobre gerenciamento de resultados parte da premissa de que essa prática ocorre por meio da manipulação dos *accruals* de uma entidade. A partir disso, diversos modelos buscaram dividir os *accruals* de uma entidade em uma parcela não discricionária (*accruals* normais) e discricionária (*accruals* anormais) (Jones, 1991; Dechow et al., 1995; Dechow & Dichev, 2002; Kothari et al., 2005; Francis et al., 2008). Portanto, esse campo de pesquisa passou a considerar a parcela discricionária dos *accruals* como uma medida que representa a prática do gerenciamento de resultados contábeis.

Porém, um problema fundamental do uso dos *accruals* consiste no fato do gerenciamento não ser diretamente mensurável. Deste modo, as atividades relacionadas ao

gerenciamento costumam ser de difícil distinção dentro das atividades normais de uma empresa, portanto, a avaliação do desempenho real desses modelos pode apresentar problemas consideráveis. Assim, estudos como de Dechow et al. (1995), Xie (2001) e Dechow et al. (2003) questionaram a capacidade dos modelos de gerenciamento de resultados em extraírem corretamente a parte discricionária dos *accruals* contábeis.

São diversos os apontamentos sobre problemas relacionados aos modelos de gerenciamento de resultados existentes. Höglund (2012) explica que o fraco desempenho dos modelos é oriundo dos ruídos que os dados possuem. Outra explicação consiste no uso de uma abordagem linear para modelar o processo de *accruals*, o que pode prejudicar o desempenho de modelos, pois estudos sugerem que esse processo é de fato, não linear (Dechow et al., 1995; Jeter & Shivakumar, 1999; Kothari et al., 2005).

Portanto, entende-se que os diversos problemas observados em modelos tradicionais de gerenciamento de resultados podem afetar a confiabilidade deste índice como medida de qualidade informacional. Com vistas a sanar problemas relacionados a modelos de gerenciamento, o uso de uma linguagem livre de tecnicismos, explicando o pensamento racional do ser humano com precisão suficiente, seria ideal (Skansi, 2018).

Assim, o uso da máquina seria uma opção, tendo em vista que por meio da Inteligência Artificial (IA), tarefas intelectuais normalmente realizadas por humanos podem ser automatizadas (Chollet, 2018). A IA é compreendida como um campo geral que engloba o *machine learning*, o qual surgiu como um sistema onde o computador é capaz de executar e aprender por si mesmo uma tarefa específica, mediante o aprendizado automático ao observar um conjunto de dados (Chollet, 2018).

A Rede Neural Artificial (RNA) está inserida no campo do *machine learning*, sendo está compreendida como um modelo matemático que tenta simular a estrutura e funcionalidades de uma rede neural biológica, ou seja, são inseridos em uma RNA *inputs* que são ponderados, somados e ativados, gerando *outputs* que passaram por um processo de aprendizado (Krenker, Bešter, & Kos, 2011). Portanto, devido à sua adaptabilidade, a utilização de RNA's representa diversas soluções para processamento de informações subjetivas, tomada de decisão e previsão (Sung, & Niyogi, 1994; Faller, & Schreck, 1995; Touzet, 1997), tornando-se assim, nos últimos anos, uma ferramenta para a tomada de decisões financeiras (Lam, 2004).

Como a RNA visa solucionar problemas observados em diversos campos, por meio da simulação de uma rede neural biológica, compreende-se o seu uso como uma ferramenta potencial que pode auxiliar na redução dos problemas observados em modelos tradicionais de gerenciamento de resultados ao estimar os *accruals* discricionários gerados pelo gestor. Portanto, este ensaio objetiva apresentar as Redes Neurais Artificiais (RNA) como abordagem que pode minimizar problemas observados em modelos de gerenciamento de resultados.

O presente estudo torna-se relevante por identificar diversos problemas em modelos de gerenciamento de resultados apontados por literaturas distintas, e fornecer soluções a esses problemas por meio do uso da tecnologia como ferramenta que pode reduzir a assimetria informacional existente em uma entidade. Por meio de um ensaio teórico, a contribuição potencial surge pela junção de peças teóricas em um único documento que pode auxiliar diversos pesquisadores na elaboração de trabalhos sobre a temática, bem como, sinalizar aos diversos usuários da informação que a máquina pode vir a auxiliar na detecção de práticas oportunistas da gestão.

O processo de tomada de decisão em uma empresa deve ser analisado com cautela, e a informação contábil existe com o propósito de auxiliar neste processo. Se o ser humano é capaz de manipular a informação contábil para benefício próprio, e a máquina é capaz de auxiliar na redução dessa manipulação, um estudo que faça essa ponte entre a qualidade da

informação e as redes neurais artificiais pode contribuir de forma substancial para a literatura contábil.

## 2.2. Corpo do Ensaio Teórico

### 2.2.1. Gerenciamento de Resultados por *Accruals*

Com vistas a apresentar de forma detalhada e crítica a literatura sobre gerenciamento de resultados, utilizou-se o estudo de Dechow et al. (2010), o qual analisou mais de 300 artigos relacionados à qualidade dos lucros, os quais basearam-se no seguinte modelo clássico:

$$\text{Reported Earnings} = f(X) \quad (1)$$

No modelo apresentado,  $X$  representa a real performance financeira da empresa em um determinado período que, por sua vez, não é observável diretamente. No entanto, torna-se necessária a existência de um sistema contábil, o qual consiste em uma função do desempenho financeiro real da entidade.

Dechow et al. (2010) abordam ruídos que reduzem a capacidade do sistema contábil de representar o real desempenho financeiro de uma empresa, sendo eles: existência de múltiplos modelos de decisões; conjunto limitado e pré-definido de princípios de mensuração para um conjunto variado de modelos de desempenho financeiro; e problemas na implementação do sistema contábil (julgamentos, estimações, etc).

O aspecto relacionado à implementação do sistema contábil é apontado como uma das fontes de ruído com maior frequência. Nessa abordagem parte-se da ideia de que os *accruals* anormais afetam negativamente a utilidade da decisão, e a partir de então, busca-se isolar a sua parcela anormal, a qual pode ser interpretada tanto como erro, tanto quanto um viés, mediante os modelos de *accruals* na contabilidade (Dechow et al., 2010). Sendo assim, a qualidade dos lucros de uma empresa depende de seu desempenho real (fator não diretamente observado) e da qualidade do sistema contábil, o qual é responsável por sua mensuração.

Um princípio básico de um sistema de mensuração baseado em um regime de competência é que os lucros contábeis suavizam as flutuações relacionadas aos fluxos de caixa, fornecendo aos resultados contábeis maior capacidade informativa sobre o desempenho de uma empresa (Dechow et al., 2010). Embora pronunciamentos contábeis não afirmem que a suavização seja uma propriedade desejável dos lucros, este atributo seria o resultado de um sistema baseado em *accruals*, assumindo que estes melhoram a utilidade da decisão (Dechow et al., 2010).

Porém, desenvolver um modelo de qualidade dos *accruals* que bem separe o papel do sistema contábil e do real desempenho é um problema que nunca será resolvido por completo, tendo em vista que o real desempenho da empresa não é observável (DeFond, 2010). Além disso, o sistema contábil pode influenciar o comportamento da administração que, por sua vez, altera o valor dos lucros e, conseqüentemente, a qualidade desses lucros (Ewert & Wagenhofer, 2011).

Pesquisas que tratam de temas relacionados à persistência dos lucros, *earnings smoothing* e *accruals* anormais abordam problemas advindos das falhas de identificação do real desempenho da empresa. Ewert e Wagenhofer (2011) apontam que o *earnings smoothing* é representado tanto como uma *proxy* de gerenciamento de resultados (qualidade dos lucros

baixa), quanto como uma parcela adicional incorporada aos lucros pelos gestores (qualidade dos lucros superior).

Já no trabalho seminal de Sloan (1996), foi apontado que o menor impacto da parcela dos *accruals* na persistência dos lucros, em comparação a parcela dos fluxos de caixa, é originada de problemas no sistema contábil. Esse problema é gerado tanto pela incapacidade de refletir o real desempenho da empresa, quanto por problemas associados à discricionariedade dos *accruals*, permitidos por esse sistema.

Porém, outra explicação foi desenvolvida sobre o menor impacto dos *accruals* na persistência dos lucros. Fairfield et al. (2003) apontam que o efeito causado pelo aumento do desempenho na persistência dos lucros está pautado na observação de que, na medida em que os setores se expandem, torna-se cada vez mais difícil manter os mesmos preços para bens negociados, o que impacta negativamente nas margens de lucro, sendo assim, a menor persistência dos resultados ocorre naturalmente pela existência de retornos marginais decrescentes, e não pela qualidade informacional dos *accruals*.

De modo geral, as evidências dos trabalhos que estudam as consequências da suavização de resultados não fornecem uma conclusão clara. A variação *cross-seccional* dessa variável pode ser resultado do próprio desempenho real da empresa, da maior ou menor capacidade representativa do sistema de mensuração contábil ou da heterogeneidade das escolhas contábeis por parte dos gestores. Tais escolhas podem ter o objetivo tanto de aumentar a utilidade das decisões, quando de distorcê-las.

Portanto, torna-se necessário a separação devida desses aspectos relacionados as consequências dos *accruals* em relação à mensuração do real desempenho da empresa, pois cada um desses elementos terá implicações distintas para a utilidade da informação, que visa auxiliar o processo de tomada de decisões (Dechow et al., 2010).

### **2.2.2. Problemas Econométricos em Modelos de Gerenciamento por *Accruals***

Em estudos que visam determinar o gerenciamento de resultados em uma entidade, a questão central consiste na estimativa dos componentes gerenciados, sendo estes denominados como *accruals* discricionários ou anormais.

Kang e Sivaramakrishnan (1995) comentam que ao prever os componentes não gerenciados (*accruals* não discricionários), há uma questão metodológica relacionada a essa previsão, pois esses números contábeis serão afetados pelo próprio processo de gerenciamento. Um ponto importante a observar nos modelos de gerenciamento, é que as medidas de *accruals* discricionários obtidas tendem a ser positivamente relacionadas com o nível de *accruals* totais (Dechow et al., 2010). Essa correlação levanta preocupações sobre se os *accruals* anormais refletem distorções contábeis ou se, em vez disso, são resultado de modelos de *accruals* mal especificados e incluem algum componente que mede o desempenho fundamental.

Portanto, Dechow et al. (2010) afirmam que os erros de classificação incorreta em modelos de *accruals* podem incluir erros do Tipo I, que classificam os *accruals* como anormais quando são uma representação do desempenho fundamental (ou seja, um falso positivo) e erros do Tipo II, que classificam os *accruals* como normais quando não são.

Algumas razões para resultados empíricos fracos e inconsistentes em modelos de gerenciamento por *accruals* são: uso de *proxies* não confiáveis para representar as parcelas gerenciadas e não gerenciadas dos lucros; foco da maioria dos estudos empíricos em um aspecto do gerenciamento de resultados por vez; interpretação restrita do gerenciamento de resultados; e incentivos dos gestores para esconder os rastros de suas ações (Sunder, 1997).

Já Arya et al. (1998) sugerem outras duas razões: os proprietários podem ter incentivos para tornar mais fácil para os gestores a ocultação de informações; e duas ou mais condições independentes que induzem o gerenciamento de resultados podem existir simultaneamente,

fazendo com que estudos que se concentram em uma única condição gerem ruído em seus resultados.

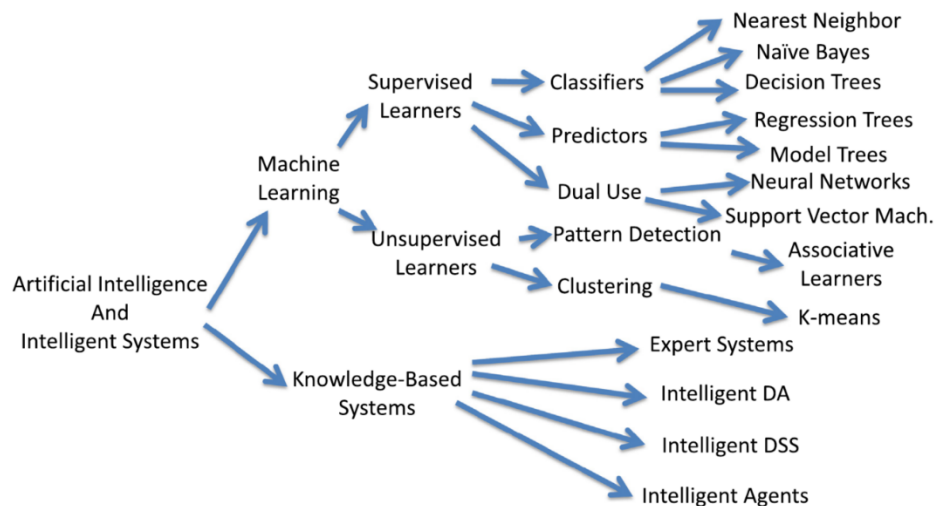
Ao analisar problemas de especificação em modelos de *accruals*, Fields et al. (2001) argumentam que mesmo os trabalhos que consideram múltiplas motivações, geralmente os tratam de forma independente. Porém, na prática, os gestores enfrentam diversos conflitos em suas decisões, sugerindo assim que suas ações não são consistentes, em média. Assim, a dificuldade na especificação de uma metodologia adequada está na complexidade das atividades envolvidas, ou seja, advém do impacto simultâneo das múltiplas escolhas e objetivos, além de complicações de identificação das relações entre elas e, finalmente, dos problemas de mensuração das *proxies* escolhidas (Fields et al., 2001). De forma semelhante, McNichols (2000) reforça a dimensão do desafio enfrentado na busca da identificação e controle de potenciais variáveis omitidas correlacionadas, visto a base teórica limitada no que diz respeito ao comportamento dos *accruals* na ausência de discricionariedade.

Outro aspecto a ser observado, de fundamental importância, refere-se ao comportamento não linear dos lucros, o qual é devido a diversos fatores. Kothari et al. (2005) destacam que desempenhos extremos tendem a reverter à média, ao passo que um desempenho médio é bastante persistente, o que implica uma relação não linear entre o desempenho atual e futuro em toda parcela da série *cross-seccional*. Outra fonte de comportamento não linear pode ser devida ao resultado da tendência dos gestores ao proceder ao uso de “*big bath*” em momentos economicamente ruins.

Outras razões que afetam negativamente o comportamento dos lucros referem-se ao conservadorismo contábil e aos incentivos para o gerenciamento dos resultados, conforme apontado pelos estudos de Watts e Zimmerman (1986), Basu (1997) e Watts (2003). Portanto, conforme observado, modelos tradicionais de gerenciamento de resultados por *accruals* são passíveis a problemas de classificação, especificação e interpretação. Assim, o uso de ferramentas para a melhor estimação dos modelos *accruals* torna-se importante com vistas a obter resultados mais próximos da realidade econômico-financeira de uma entidade.

### 2.2.3. Inteligência Artificial, *Machine Learning* e Redes Neurais Artificiais


Uma Inteligência Artificial (IA) consiste em um esforço para automatizar tarefas intelectuais que normalmente são realizadas por humanos. Portanto, a IA representa um campo geral que engloba abordagens que envolvem aprendizado, bem como engloba também outras abordagens que não envolvem aprendizado (Chollet, 2018). São diversos os ramos de aplicação da IA, e para uma melhor compreensão, esses são evidenciados na figura a seguir:



**Figura 1:** Ramos de aplicação da Inteligência Artificial.

**Fonte:** Sutton et al. (2016).

Embora a IA tenha se mostrado adequada para resolver problemas lógicos bem definidos, tais como jogar xadrez, tornou-se impraticável descobrir regras explícitas para resolver problemas mais complexos e imprecisos. Assim, uma nova abordagem surgiu para ocupar o lugar simbólico da IA, sendo esta denominada como *machine learning* (Chollet, 2018). Ressalta-se que a IA representa um campo mais abrangente, que envolve a abordagem do *machine learning*, bem como a abordagem do *deep learning*, conforme figura a seguir:




**Figura 2:** Campos da Inteligência Artificial.

**Fonte:** Chollet (2018).

O *machine learning* surgiu a partir da seguinte questão: um computador poderia ir além do que sabemos ordenar que ele execute e aprender por si mesmo como executar uma tarefa específica? Ou seja, em vez de programadores elaborando regras para o processamento de dados manualmente, busca-se descobrir se um computador poderia aprender automaticamente essas regras observando os dados (Chollet, 2018).

A questão acima apresentada abre porta para um novo paradigma de programação, pois na programação clássica, com base no paradigma da IA, um humano insere as regras de entrada, assim como dados a serem processados de acordo com essas regras, obtendo assim, um resultado com as respostas, já com o *machine learning*, os humanos inserem os dados, bem como as respostas esperadas, e como resultado, se obtêm as regras. Assim, essas regras poderão ser aplicadas a novos dados com vistas a produzir respostas originais (Chollet, 2018). Esses dois paradigmas são melhor ilustrados na figura a seguir:



**Figura 3:** Programação Clássica vs *Machine Learning*.

**Fonte:** Chollet (2018).


Deste modo, um sistema baseado no paradigma do *machine learning* é treinado em vez de programado. Para tanto, torna-se necessário a apresentação de muitos exemplos relevantes para uma tarefa, para que se possa encontrar uma estrutura estatística nesses



exemplos, que, eventualmente permite ao sistema criar regras para automatizar a tarefa (Chollet, 2018).

Assim, um modelo de aprendizado de máquina transforma seus dados de entrada em saídas mais significativas, pois este processo é “aprendido” a partir da exposição a exemplos conhecidos de entradas e saídas. Portanto, o problema central no aprendizado de máquina e no aprendizado profundo (*deep learning*) consiste em transformar dados de forma significativa, ou seja, aprender representações que sejam úteis na aproximação dos resultados esperados, a partir dos dados de entrada que foram disponibilizados (Chollet, 2018).

A Rede Neural Artificial (RNA) é considerada como uma das ferramentas inseridas no campo do *machine learning* e é considerada como um modelo matemático que tenta simular a estrutura e funcionalidades de redes neurais biológicas (Krenker et al., 2011). Um esquema matemático de uma rede neural artificial é evidenciado a seguir:




**Figura 4:** Esquema matemático de um Neurônio Artificial.

**Fonte:** Krenker et al. (2011).

A Figura 4 acima apresenta o bloco de construção básico de uma rede neural artificial (ou neurônio artificial), sendo essa composta por um modelo matemático simples (função). Neste modelo, existem três conjuntos simples de regras, sendo elas: multiplicação, soma e ativação. Na entrada do neurônio artificial, os *inputs* são ponderados, o que significa que cada *input* é multiplicado por um peso individual. Na seção intermediária do neurônio artificial, existe a função que soma todas as entradas ponderadas e o viés. Na saída do neurônio artificial, a soma dos *inputs* previamente ponderados e do viés passa pela função de ativação, que também é chamada de função de transferência (Krenker et al., 2011).

Há diferenças a serem observadas ao se comparar um neurônio artificial (ou rede neural artificial) com um neurônio biológico. Um comparativo entre o neurônio artificial e o biológico é melhor evidenciado conforme figura a seguir:



**Figura 5:** Neurônio biológico vs neurônio artificial.

**Fonte:** Krenker et al. (2011).

Em um neurônio biológico, a informação entra no dendrito (parcela do corpo neural), o corpo do neurônio (soma) processa a informação e a transmite via axônio (uma parcela do neurônio que é tipicamente mais longa que os dendritos). Já em um neurônio artificial, a informação chega por meio de entradas que são ponderadas (cada entrada pode ser multiplicada individualmente por um peso). Por conseguinte, o corpo do neurônio artificial soma as entradas ponderadas e o viés, e “processa” a soma com uma função de transferência. No final, um neurônio artificial passa a informação processada via *outputs* (Krenker et al., 2011).

Mediante exposto, entende-se que uma rede neural artificial pode ser capaz de receber informações e gerar resultados que aprendem a cada rodada de dados recebidos. Assim, espera-se que essa ferramenta pode ser utilizada para corrigir alguns problemas encontrados em modelos contábeis, pois a máquina aprende por meio de vários dados que serão recebidos, ponderados e ativados.

#### 2.2.4. Redes Neurais Artificiais e Gerenciamento por *Accruals*

Diversas técnicas existentes utilizadas para medir o gerenciamento de resultados tem apresentado baixo poder, devido à pouca capacidade dos modelos em isolar os *accruals* discricionários. Além disso, testes realizados com essas técnicas são incorretamente especificados devido a variáveis omitidas em amostras com desempenho financeiro extremo, situação não incomum em testes de gerenciamento de resultados (Dechow et al., 2012).

Assim, as Redes Neurais Artificiais (RNA) apresentam algumas vantagens que podem ser utilizadas em modelos de gerenciamento de resultados. Em primeiro lugar, uma RNA possui a capacidade de “aprender” e desenvolver um mapeamento de qualquer estrutura não-linear complexa. Em segundo lugar, uma RNA não exige a determinação de suposições *priori* sobre a distribuição dos dados analisados. E por fim, em terceiro lugar, pode-se enfatizar o alto nível de flexibilidade no que diz respeito a dados incompletos, ausentes e com alto grau de ruído (Vellido et al., 1999).

Portanto, conseqüentemente, uma RNA possui características importantes na superação dos principais problemas associados aos modelos tradicionais na detecção do gerenciamento de resultados e tem o potencial de desenvolver modelos de previsão para identificar o nível do gerenciamento de resultados. Assim, a primeira questão de pesquisa é baseada na possível superioridade da metodologia proporcionada pela abordagem das Redes Neurais Artificiais em relação ao método da regressão, conforme segue:

**Questão 1:** A utilização das Redes Neurais Artificiais proporciona maiores níveis de poder e especificidade em modelos de detecção de gerenciamento de resultados do que a utilização das abordagens baseadas em regressão linear?

Um aspecto de suma importância a ser discutido sobre modelos de gerenciamento de resultados é descrito por Scott (2015). Uma lei fundamental (*iron law*) deste processo é baseada no regime de competência, onde torna-se necessária a reversão dos *accruals*. Portanto, sempre que ocorre um gerenciamento positivo dos lucros, a um valor maior do que

pode ser sustentado, a reversão desses *accruals* em períodos subsequentes forçará os lucros para baixo.

Em contrapartida, os *accruals* não discricionários estão vinculados às operações subjacentes aos negócios da empresa. Tais *accruals* tendem a se originar em períodos de crescimento das operações, ou quando ocorrem mudanças estratégicas em decisões operacionais e/ou de investimento (McNichols, 2000).

Baseando na perspectiva de que as empresas operam em um contexto de continuidade, suas características operacionais tendem a persistir, assim como os *accruals* não discricionários relacionados. Assim, de forma geral, a reversão de *accruals* não discricionários tende a ser compensada por outros de mesma natureza, exibindo, de forma agregada, persistência ao longo do tempo (Dechow et al., 2012).

Assim, baseado nessa lei, Dechow et al. (2012) propuseram um procedimento para abordar os problemas associados às técnicas tradicionais, incorporando as informações dos pesquisadores sobre a reversão dos *accruals* discricionários. Esta abordagem pode ser adaptada para utilização em todos os modelos tradicionais de gerenciamento de resultados com base em *accruals*.

Porém, Dechow et al. (2012) destacam que este procedimento requer que os períodos em que se espera que os *accruals* sejam manipulados sejam identificados previamente, assim como os de expectativa de suas reversões. Assim, uma questão de pesquisa pode estar relacionada a verificar se utilização da RNA para a determinação de tais períodos promove melhores no poder e especificidade do modelo inicial, conforme segue:

**Questão 2:** A utilização das Redes Neurais Artificiais na determinação dos períodos de início da manipulação dos *accruals*, assim como dos períodos de reversão, melhora o poder e especificidade do modelo proposto por Dechow et al. (2012)?

Com relação à não linearidade constante em modelos tradicionais de gerenciamento de resultados, Kothari et al. (2005) destacam que, a menos que os modelos de *accruals* discricionários sejam adaptados para lidar com este problema, não há razão para esperar que a abordagem de regressão seja eficaz no controle de *accruals* discricionários diferentes de zero em amostras estratificadas aleatórias. Os autores evitaram a superação deste problema por meio de modelos de regressões não lineares, justificando a escolha com base na ausência de uma teoria para orientar tal modelagem, o que implica na necessidade de testar uma quantidade de especificações acima do razoável, além de poder gerar problemas relacionados ao *overfitting*.

A escolha metodológica do estudo de Kothari et al. (2005), em contraste com a abordagem de regressão, foi baseada no confronto da parcela discricionária dos *accruals* das empresas do mesmo segmento, com base em suas performances (*performance matched approach*). Esta abordagem assume que, em média, as empresas do grupo de tratamento e de controle têm os mesmos *accruals* discricionários não relacionados ao evento estudado (performance).

Assim, entende-se que o poder do modelo de Kothari et al. (2005) reside na capacidade em determinar, de forma razoável, a melhor seleção para os grupos de controle e tratamento na detecção do gerenciamento de resultados. Portanto, a terceira e última questão de pesquisa pode ser delineada conforme segue:

**Questão 3:** A utilização das Redes Neurais Artificiais na determinação dos grupos de controle e tratamento, melhora o poder e especificidade do modelo proposto por Kothari et al. (2005)?

As questões de pesquisa abordadas nesta seção possuem como intuito direcionar pesquisadores, principalmente, na utilização de RNAs para a melhora do poder e especificidade de modelos tradicionais de gerenciamento de resultados, com uma ênfase nos modelos de Kothari et al. (2005) e Dechow et al. (2012) por esses serem os modelos mais contemporâneos propostos. Espera-se que as discussões aqui apresentadas possam fornecer um suporte a diversos estudiosos sobre problemas observados nos modelos tradicionais e direcionem a possibilidades de uso de métodos mais complexos para correção desses problemas.

### 2.3. Considerações Finais

A assimetria de informação entre participantes em um contrato de agência tem gerado, ao longo do tempo, diversas discussões acerca da maximização de interesse entre uma das partes de um contrato. Assim, a informação gerada pela contabilidade tem potencial de minimizar essa assimetria, principalmente quando esta informação é gerada com qualidade.

Porém, a gestão de uma empresa tem adotado a prática do gerenciamento de resultados de informações contábeis, mediante julgamentos e escolha de métodos que acabam não refletindo de forma precisa os fenômenos de uma empresa, prejudicando assim a qualidade da informação gerada pela empresa (Healy & Wahlen, 1999), agravando assim a assimetria, ao invés de minimizá-la.

Diversos estudiosos desenvolveram modelos que visam mensurar a parcela gerenciada do lucro contábil, com vistas a obter um valor que represente uma medida confiável sobre um possível oportunismo da gestão, porém, o uso dos *accruals* para mensurar esse gerenciamento tem apresentado problemas, por diversos apontamentos realizados em trabalhos anteriores (Dechow et al., 1995; Jeter & Shivakumar, 1999; Xie, 2001; Dechow et al., 2003; Kothari et al., 2005; Höglund, 2012).

Modelos tradicionais de gerenciamento de resultados apresentam: problemas de especificação em modelos; comportamento não linear dos lucros; conservadorismo contábil; presença de incentivos; variáveis omitidas, entre outros. Portanto, torna-se necessário que formas de melhor estimação de modelos de *accruals* sejam implementadas com vistas a se obter uma melhor medida de representação da realidade econômica da empresa.

Portanto, este trabalho apresentou a Rede Neural Artificial (RNA) como uma ferramenta que pode corrigir problemas apresentados pelos modelos tradicionais de gerenciamento de resultados. Vellido et al. (1999) apresenta três vantagens do uso da RNA em modelos de gerenciamento de resultados: capacidade de aprender e desenvolver um mapeamento de qualquer estrutura não-linear complexa; não exigência na determinação de suposições sobre a distribuição dos dados; e alto nível de flexibilidade no que diz respeito a dados incompletos. Portanto, essa ferramenta pode apresentar uma saída aos problemas observados nesses modelos contábeis de gerenciamento de resultados.

Foram delineadas três questões de pesquisa que representam possíveis efeitos do uso de RNAs nos modelos de gerenciamento de resultados por *accruals*: a utilização de RNAs pode proporcionar maiores níveis de poder e especificidade em modelos de gerenciamento de resultados do que a utilização das abordagens baseadas em regressão linear; a utilização das RNAs na determinação dos períodos de início da manipulação dos *accruals*, assim como dos períodos de reversão, melhora o poder e especificidade do modelo proposto por Dechow et al. (2012); e a utilização das RNAs na determinação dos grupos de controle e tratamento, melhora o poder e especificidade do modelo proposto por Kothari et al. (2005).

Assim, pode-se observar que essa ferramenta tecnológica possui um poder de melhor apurar os *accruals* em comparação aos modelos tradicionais de gerenciamento de resultados,

mediante maior nível de poder e especificidade, bem como na melhor determinação dos períodos de início e reversão, e grupos de controle e tratamento de modelos amplamente conhecidos e utilizados.

Espera-se que este trabalho possa contribuir com uma maior instigação ao uso de ferramentas computacionais na apuração de valores não diretamente observáveis pela contabilidade, bem como no incremento de discussões sobre o uso de ferramentas tecnológicas para solucionar problemas econométricos observados em modelos que apuram a qualidade da informação contábil. Assim, espera-se que haja uma melhora na apuração dessas variáveis não diretamente observáveis, bem como um avanço nos estudos relacionados aos temas sobre gerenciamento de resultados e qualidade da informação contábil, mediante a integração da ciência contábil com a tecnologia da informação.

Este trabalho limita-se por centrar-se somente no uso de Redes Neurais Artificiais como única ferramenta possível que possa solucionar os problemas observados em modelos tradicionais de gerenciamento, tendo em vista que no ramo da Inteligência Artificial existem diversos outros métodos. Porém, justifica-se pela oportunidade de explorar uma ferramenta importante de forma mais profunda, com maior aplicação na correção de problemas observados nesses modelos de gerenciamento por *accruals*. Assim, sugere-se para pesquisas futuras uma ampliação das ferramentas advindas da Inteligência Artificial em modelos de qualidade da informação contábil.

## Referências

- Arya, A., Glover, J., & Sunder, S. (1998). Earnings management and the revelation principle. *Review of Accounting Studies*, 3(1–2), 7–34. <https://doi.org/10.1023/a:1009631714430>
- Basu, S. (1997). The conservatism principle and the asymmetric timeliness of earnings. *Journal of Accounting and Economics*, 31(3), 3–37. <https://doi.org/10.1177/0962280211413449>
- Berle, A. A., & Means, G. G. C. (1932). The Modern Corporation and Private Property. In *The Modern Corporation and Private Property (First)*. Harcourt, Brace & World, Inc. <https://doi.org/10.4324/9781315133188>
- Black, R., & Nakao, S. H. (2017). Heterogeneidade na qualidade do lucro contábil entre diferentes classes de empresas com a adoção de IFRS: evidências do Brasil. *Revista Contabilidade e Finanças*, 28(73), 113–131. <https://doi.org/10.1590/1808-057x201702750>
- Chollet, F. (2018). *Deep Learning with Python (First)*. Manning Publications Co.
- Dechow, P., & Dichev, I. D. (2002). The Quality of Accruals and Earnings: The Role of Accruals Estimation Errors. *The Accounting Review*, 77(2002), 35–59. <https://doi.org/10.2308/accr.2002.77.s-1.61>
- Dechow, P., Ge, W., & Schrand, C. (2010). Understanding earnings quality: A review of the proxies, their determinants and their consequences. *Journal of Accounting and Economics*, 50(2–3), 344–401. <https://doi.org/10.1016/j.jacceco.2010.09.001>
- Dechow, P. M., Hutton, A. P., Kim, J. H., & Sloan, R. G. (2012). Detecting Earnings Management: A New Approach. *Journal of Accounting Research*, 50(2), 275–334. <https://doi.org/10.1111/j.1475-679X.2012.00449.x>
- Dechow, P. M., Richardson, S. A., & Tuna, I. (2003). Why Are Earnings Kinky? An Examination of the Earnings Management Explanation. *Review of Accounting Studies* 2003 8:2, 8(2), 355–384. <https://doi.org/10.1023/A:1024481916719>
- Dechow, P. M., Sloan, R. G., & Sweeney, A. P. (1995). Detecting Earnings Management. *The Accounting Review*, 70(2), 193–225. <https://doi.org/10.2307/248303>
- DeFond, M. L. (2010). Earnings quality research: Advances, challenges and future research. *Journal of Accounting and Economics*, 50(2–3), 402–409. <https://doi.org/10.1016/j.jacceco.2010.10.004>
- Ewert, R., & Wagenhofer, A. (2011). Earnings Management, Conservatism, and Earnings Quality. *Foundations and Trends in Accounting*, 6(2), 65–186. <https://doi.org/10.1561/14000000025>
- Fairfield, P. M., Whisenant, S., & Yohn, T. L. (2003). The Differential Persistence of Accruals and Cash Flows for Future Operating Income versus Future Profitability. *Review of Accounting Studies*, 8(2), 221–243. <https://doi.org/10.1023/A:1024413412176>
- Faller, W. E., & Schreck, S. J. (1995). Real-Time Prediction of Unsteady Aerodynamics: Application for Aircraft Control and Maneuverability Enhancement. *IEEE Transactions on Neural Networks*, 6(6), 1461–1468. <https://doi.org/10.1109/72.471362>

- Fama, E. F. (1980). Agency Problems and the Theory of the Firm. *Journal of Political Economy*, 88(2), 288–307. <https://doi.org/10.1086/260866>
- Fields, T. D., Lys, T. Z., & Vincent, L. (2001). Empirical research on accounting choice. *Journal of Accounting and Economics*, 31(1–3), 255–307. [https://doi.org/10.1016/S0165-4101\(01\)00028-3](https://doi.org/10.1016/S0165-4101(01)00028-3)
- Francis, J., Olsson, P., & Schipper, K. (2008). Earnings Quality. *Foundations and Trends in Accounting*, 1(4), 259–340. <https://doi.org/10.1561/1400000004>
- Healy, P. M., & Wahlen, J. M. (1999). A Review of the Earnings Management Literature and Its. *Accounting Horizons*, 13(4), 365–383. <https://doi.org/10.2308/acch.1999.13.4.365>
- Jensen, M. C., & Meckling, W. H. (1976). Theory of the firm: Managerial behavior, agency costs and ownership structure. *Journal of Financial Economics*, 3(4), 305–360.
- Jeter, D. C., & Shivakumar, L. (1999). Cross-sectional estimation of abnormal accruals using quarterly and annual data: effectiveness in detecting event-specific earnings management. *Accounting and Business Research*, 29(4), 299–319. <https://doi.org/10.1080/00014788.1999.9729590>
- Jones, J. J. (1991). Earnings Management During Import Relief Investigations. *Journal of Accounting Research*, 29(2), 193. <https://doi.org/10.2307/2491047>
- Kang, S. H., & Sivaramakrishnan, K. (1995). Issues in Testing Earnings Management and an Instrumental Variable Approach. *Journal of Accounting Research*, 33(2), 353. <https://doi.org/10.2307/2491492>
- Kothari, S. P., Leone, A. J., & Wasley, C. E. (2005). Performance matched discretionary accrual measures. *Journal of Accounting and Economics*, 39(1), 163–197. <https://doi.org/10.1016/j.jacceco.2004.11.002>
- Krenker, A., Bešter, J., & Kos, A. (2011). Introduction to the Artificial Neural Networks, In: Suzuki K (ed), *Artificial Neural Networks: Methodological Advances and Biomedical Applications*. InTech, 1–18. <http://www.intechopen.com/books/artificial-neural-networks-methodological-advances-and-biomedical-applications/introduction-to-the-artificial-neural-networks>
- Lam, M. (2004). Neural network techniques for financial performance prediction: integrating fundamental and technical analysis. *Decision Support Systems*, 37(4), 567–581. [https://doi.org/10.1016/S0167-9236\(03\)00088-5](https://doi.org/10.1016/S0167-9236(03)00088-5)
- McNichols, M. F. (2000). Research design issues in earnings management studies. *Journal of Accounting and Public Policy* 19(4–5). [https://doi.org/10.1016/S0278-4254\(00\)00018-1](https://doi.org/10.1016/S0278-4254(00)00018-1)
- Salgado, N. de N. B., & Souza, P. V. S. de. (2021). The Effect of Accounting Timeliness on Earnings Management for Brazilian Companies Listed on B3. *Advances in Scientific and Applied Accounting*, 14(1), 039–055 / 056. <https://doi.org/10.14392/asaa.2021140102>
- Scott, W. R. (2015). *Financial accounting theory* (Seventh). Pearson Canada Inc.
- Skansi, S. (2018). *Introduction to Deep Learning*. In *Deep Reinforcement Learning: Fundamentals, Research and Applications*. <https://doi.org/10.1007/978-3-319-73004-2>
- Sloan, R. G. (1996). Do Stock Prices Fully Refelct Information in Accruals and Cash Flows About Future Earnings? *The Accounting Review*, 71(3), 289–315.

- Subramaniam, N. (2006). Agency theory and accounting research: an overview of some conceptual and empirical issues. In Z. Hoque (Ed.), *Methodological issues in accounting research: theories and methods*, 55–81. Spiramus Press.
- Sunder, S. (1997). *Theory of Accounting and Control*. South-Western College Publishing.
- Sung, K., & Niyogi, P. (1994). *Active Learning for Function Approximation*. In G. Tesauro, D. Touretzky, & T. Leen (Eds.), *Advances in Neural Information Processing Systems* (Vol. 7). MIT Press.  
<https://proceedings.neurips.cc/paper/1994/file/acf4b89d3d503d8252c9c4ba75ddb6d-Paper.pdf>
- Sutton, S. G., Holt, M., & Arnold, V. (2016). The reports of my death are greatly exaggerated. Artificial intelligence research in accounting. *International Journal of Accounting Information Systems*, 22, 60–73. <https://doi.org/10.1016/j.accinf.2016.07.005>
- Touzet, C. F. (1997). Neural reinforcement learning for behaviour synthesis. *Robotics and Autonomous Systems*, 22(3–4), 251–281. [https://doi.org/10.1016/S0921-8890\(97\)00042-0](https://doi.org/10.1016/S0921-8890(97)00042-0)
- Vellido, A., Lisboa, P. J. G., & Vaughan, J. (1999). Neural networks in business: a survey of applications (1992–1998). *Expert Systems with Applications*, 17(1), 51–70.  
[https://doi.org/10.1016/S0957-4174\(99\)00016-0](https://doi.org/10.1016/S0957-4174(99)00016-0)
- Watts, R. L. (2003). Conservatism in Accounting Part I: Explanations and Implications. *Accounting Horizons*, 17(3), 207–221. <https://doi.org/10.2308/ACCH.2003.17.3.207>
- Watts, R. L., & Zimmerman, J. L. (1986). *Positive Accounting Theory*. Prentice-Hall Inc.
- Xie, H. (2001). The Mispricing of Abnormal Accruals. *The Accounting Review*, 76(3), 357–373. <https://doi.org/10.2308/ACCR.2001.76.3.357>



### **3. Detecção de Gerenciamento de Resultados com Base em Simulações Utilizando a Abordagem de Reversões de *Accruals*.**

#### ***Detection of Earnings Management Based on Simulations Using the Accrual Reversal Approach.***

##### **Resumo**

Este estudo investiga a reversão de distorções em *accruals* e sua aplicação nos modelos tradicionais de gerenciamento de resultados em empresas brasileiras de capital aberto. Utilizando dados de 282 empresas não financeiras negociadas na B3 de 2010 a 2022, o estudo emprega a metodologia proposta por Dechow et al. (2012) para avaliar melhorias nos modelos. Duas abordagens são consideradas: uma com seleções aleatórias de observações firma-trimestre e outra com inclusão artificial de gerenciamento e suas reversões. Os resultados revelam que os modelos baseados em *accruals* têm baixo poder de teste para gerenciamento em magnitudes plausíveis. Mesmo com a inclusão de reversões, a taxa de rejeição da hipótese nula de ausência de gerenciamento dos testes se mostrou, menor do que 30%. O estudo destaca a complexidade dos modelos de *accruals* não discricionários e a correlação entre determinantes de gerenciamento e características econômicas.

**Palavras-chave:** Gerenciamento de Resultados. *Accruals*. Simulações. Reversões.

##### **Abstract**

*This study explores the reversal of accrual distortions and its application in traditional earnings management models in Brazilian publicly traded companies. Using data from 282 non-financial firms traded on B3 from 2010 to 2022, the study employs the methodology proposed by Dechow et al. (2012) to assess improvements in the models. Two approaches are considered: one with random selections of firm-year observations and another with artificially included earnings management and its reversals. The results reveal that accrual-based models have low testing power for earnings management in plausible magnitudes. Even with the inclusion of reversals, the tests do not reject the null hypothesis of no earnings management in less than 30% of the observations. The study highlights the complexity of non-discretionary accrual models and the correlation between earnings management determinants and economic characteristics.*

**Keywords:** Earnings Management. *Accruals*. Simulations. Reversals.

### 3.1. Introdução

No domínio da investigação contábil, a demarcação entre *accruals* “normais” e “anormais” constitui um ponto central, destacando as complexidades intrínsecas dos relatórios financeiros. Esta distinção baseia-se no esforço de modelar diretamente o processo de *accruals*, separando o que se consideram “normais”, servindo como um meio de encapsular elementos contábeis que refletem fielmente o desempenho fundamental das empresas, enquanto a parcela “anormal” dos *accruals* visa representar distorções induzidas pela aplicação de regras contábeis ou, em certos casos, por manobras estratégicas de gerenciamento de resultados. Esta demarcação, conforme destacado por Dechow, Sloan e Sweeney (1995), exige que se lide com os meandros inerentes ao sistema contábil, o que a torna particularmente importante em pesquisas na área contábil.

Parte das pesquisas sobre práticas de gerenciamento de resultados partem da premissa de que essa ocorre, primariamente, através da manipulação dos *accruals*. A partir de então, vários modelos (por exemplo, Jones, 1991; Dechow et al., 1995; Dechow & Dichev, 2002; Kothari et al., 2005; Francis et al., 2005) buscam dividir os *accruals* em uma parcela considerada não discricionária (*accruals* normais) e discricionária (*accruals* anormais). A parcela discricionária estimada com base nesses modelos é considerada uma *proxy* para o gerenciamento de resultados.

Um problema fundamental de tal abordagem é que o gerenciamento de resultados não é mensurável diretamente. Desta forma, as atividades relacionadas a tal prática costumam ser de difícil distinção, dentro do universo de atividades normais dos negócios. Assim, a avaliação do desempenho real desses modelos pode ser problemática. A capacidade dos modelos na identificação da parte discricionária dos *accruals* foi questionada em diversos estudos (por exemplo, Dechow et al., 1995; Xie (2001); Dechow et al., 2003). Thomas e Zhang (2000), por exemplo, concluíram que a maioria desses modelos apresenta desempenho pior do que apenas a simples suposição de que os *accruals* discricionários equivalem a 5% dos ativos totais.

Uma explicação para o fraco desempenho dos modelos é que os dados geralmente possuem bastante ruído (Höglund, 2012). Outra possível explicação é que a maioria dos modelos usa uma abordagem linear para modelar o processo de *accruals*, o que pode prejudicar o desempenho dos modelos, pois os resultados de vários estudos sugerem que tal processo, de fato, é não linear (Dechow, Sloan, & Sweeney, 1995; Jeter & Shivakumar, 1999; Kothari, Leone, & Wasley, 2005).

Modelos alternativos para modelar *accruals*, como os propostos por Dechow e Dichev (2002), deixaram dúvidas quanto à sua eficácia na melhoria da detecção do gerenciamento de resultados, conforme destacado por Wysocki (2009). Mesmo os procedimentos baseados em comparação de desempenho (*performance-matching*), adotados com a intenção de mitigar os problemas de especificação, não escaparam ao escrutínio e continuam a apresentar problemas econométricos que implicam na redução do poder dos testes. Observou-se que a sua eficácia depende significativamente do emprego preciso da variável omitida relevante, o que representa um conjunto próprio de desafios na análise empírica.

Este artigo se insere neste contexto de pesquisas e visa produzir *insights* que contribuam na busca de superação das limitações inerentes a esta área, oferecendo novas perspectivas e metodologias que prometem melhorar a precisão, o poder e a especificidade da detecção do gerenciamento de resultados. Através desta exploração, pretendemos contribuir

significativamente para o discurso mais amplo sobre a investigação contábil e as suas implicações tanto para a investigação académica como para a aplicação prática.

### 3.2. Referencial

Um dilema fundamental nas discussões sobre gerenciamento de resultados gira em torno do equilíbrio da importância de dados contábeis relevantes e confiáveis. Se a ênfase for colocada apenas na fiabilidade, a gestão reportará apenas os fluxos de caixa que tenham sido realizados. Por outro lado, priorizar a relevância focaria no valor atual dos fluxos de caixa futuros esperados (Dechow, 1994). No entanto, embora a relevância e a fiabilidade no relato não sejam totalmente incompatíveis, um aumento na relevância conduz frequentemente a uma diminuição na fiabilidade dos dados contábeis reportados.

A questão surge porque relatórios relevantes necessitam de várias estimativas feitas pela administração da empresa, introduzindo um elemento de subjetividade. Como estas estimativas são difíceis de verificar, tornam-se suscetíveis à manipulação por parte dos gestores (Sloan, 1999). Apesar dos desafios associados à prestação de informações relevantes, é essencial um equilíbrio entre relevância e fiabilidade nos dados contábeis. Os princípios contábeis geralmente aceitos permitem alguma discricção nos relatórios.

#### 3.2.1. Modelos de Detecção de Gerenciamento de Resultados

Os modelos de *accruals* discricionários surgiram como ferramentas cruciais na literatura de gerenciamento de resultados. Com foco no modelo proposto por Dechow et al. (2012), explora-se o desenvolvimento, os desafios e as implicações desses modelos na compreensão da dinâmica do gerenciamento de resultados.

A base para modelos de *accruals* discricionários foi proposta por Healy (1985) e Jones (1991). Healy reconheceu a importância de distinguir entre *accruals* discricionários e não discricionários, destacando que os gestores possuem poder discricionário significativo sobre o processo de *accrual*, utilizando-o para mascarar o desempenho fundamental. O modelo de Jones definiu os *accruals* em função do crescimento das Vendas e do Ativo Imobilizado. Embora intuitivamente razoável, o modelo de Jones apresenta um poder explicativo limitado, captando apenas cerca de 10% da variação nos *accruals*. Esta limitação ressaltou a necessidade de modelos mais refinados, capazes de abordar as complexidades do gerenciamento de resultados (Jones, 1991).

Para aumentar a precisão dos modelos de *accruals* e reduzir erros do Tipo II (não detectar o gerenciamento de resultados quando presente), Dechow et al. (1995) introduziram modificações no modelo de Jones. Ajustaram-se ao crescimento das Vendas a prazo, a variação nos Recebíveis, um alvo comum de manipulação. Este ajuste teve como objetivo produzir resíduos não correlacionados com os *accruals* de receitas, proporcionando assim melhores informações sobre a manipulação de destas. Contudo, o modelo de Jones modificado ainda apresentava erros do Tipo I (identificar o gerenciamento de resultados quando não presente).

Kothari, Leone e Wasley (2005) abordaram preocupações sobre as correlações entre o desempenho e os *accruals* discricionários e modificaram o modelo de Jones, sugerindo

correspondência de desempenho (*performance matching*). Eles propuseram a comparação entre empresas com base no Retorno Sobre os Ativos (ROA) e a dedução dos *accruals* discricionários da empresa da amostra de controle daqueles da empresa da amostra de teste para gerar resíduos após a “correspondência de desempenho”. Embora esta abordagem tenha atenuado alguns problemas, introduziu ruído e poderia reduzir o poder de teste, especialmente quando os lucros eram gerenciados (Kothari et al., 2005).

Os pesquisadores subsequentes construíram sobre essas bases. Collins *et al.* (2017) ampliaram a correspondência considerando o crescimento das vendas juntamente com o ROA. Wang, Zhang e Zhang (2012) incorporaram os retornos das ações do período atual em modelos de *accruals* para capturar o desempenho futuro antecipado da empresa. Ball e Shivakumar (2006) introduziram um modelo de *accrual* não linear, contabilizando as associações assimétricas de *accruals* com ganhos e perdas.

Dechow e Dichev (2002) propuseram uma perspectiva inovadora, enfatizando a função de adequação dos *accruals* aos fluxos de caixa. Eles modelaram os *accruals* em função dos fluxos de caixa atuais, passados e futuros, levando em consideração a natureza antecipatória dos *accruals*. Embora se concentrassem nos *accruals* de capital de giro de curto prazo, o seu modelo oferecia maior poder explicativo, com o desvio padrão dos resíduos servindo como *proxy* para a qualidade dos lucros. Esta abordagem, no entanto, poderia reduzir o poder de teste em cenários onde a gestão de resultados esperada ocorre numa direção específica.

Apesar desses refinamentos, desafios e limitações persistem. Modelos de *accruals* discricionários, incluindo Dechow et al. (2012), enfrentam problemas de erros Tipo I e Tipo II, especialmente quando aplicados a empresas com desempenho financeiro extremo (Dechow et al., 1995; McNichols, 2000). A correspondência de desempenho, ao mesmo tempo que tenta mitigar a especificação incorreta, pode introduzir ruído e reduzir o poder do teste (Kothari et al., 2005).

A literatura sobre modelos de *accruals* discricionários evoluiu significativamente, desde modelos iniciais como Jones até abordagens mais sofisticadas como Dechow et al. (2012). Estes modelos forneceram informações valiosas sobre a gestão de resultados e a qualidade dos relatórios financeiros. No entanto, os desafios atuais em termos de erros do Tipo I e do Tipo II sublinham a necessidade de aperfeiçoamento e inovação contínuos neste domínio, buscando modelos mais precisos e robustos para avaliar a qualidade dos resultados.

### 3.3. Metodologia

O presente trabalho segue uma linha metodológica semelhante a utilizada em Dechow, Sloan e Sweeney (1995) e Dechow et al. (2012) com o objetivo de examinar a especificação e o poder dos modelos de detecção de gerenciamento de resultados tradicionais.

#### 3.3.1. Amostra

A amostra desta pesquisa conta com 282 empresas não financeiras com ações negociadas na B3 entre os anos de 2010 (quarto trimestre) e 2022 (quarto trimestre). Os dados utilizados foram retirados das Demonstrações Financeiras em frequência trimestral, representando um total de 7.866 observações firma-trimestre.

#### 3.3.2. Modelos Utilizados no Trabalho

Os modelos de detecção de gerenciamento de resultados testados neste trabalho envolvem a determinação de dois aspectos: *proxy* representativa dos *accruals* totais e determinantes da parcela não discricionária dos *accruals* totais. Desta forma, seguindo Dechow et al. (2012), temos:

$$Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \sum_k f_k X_{kit} + \varepsilon_{mit} \quad (1)$$

Onde:

|                     |   |
|---------------------|---|
| $Wc\_Acc_{it}$      | = <i>Proxy</i> dos <i>accruals</i> totais da empresa $i$ , no período $t$ ;   |
| $P_{it}$            | = Variável <i>dummy</i> que assume valor 1 para observações com gerenciamento e 0, caso contrário;  |
| $PR1_{it}$          | = Variável <i>dummy</i> que assume valor 1 para observações com reversão do gerenciamento no ano subsequente à indução e 0, caso contrário;         |
| $PR2_{it}$          | = Variável <i>dummy</i> que assume valor 1 para observações com reversão do gerenciamento no segundo ano subsequente à indução e 0, caso contrário; |
| $X_{kit}$           | = Variáveis de controle da parcela não discricionária dos <i>accruals</i> para cada modelo;   |
| $\varepsilon_{mit}$ | = Termo de erro da regressão para cada modelo $m$ .   |

Por sua vez, a *proxy* para *accruals* totais é determinada da seguinte forma:

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1} \quad (2)$$

Onde:

|                    |   |
|--------------------|---|
| $\Delta CA_{it}$   | = Variação do Ativo Circulante da empresa $i$ , no período $t$ ;          |
| $\Delta CL_{it}$   | = Variação do Passivo Circulante da empresa $i$ , no período $t$ ;        |
| $\Delta Cash_{it}$ | = Variação do Caixa da empresa $i$ , no período $t$ ;                     |
| $\Delta STD_{it}$  | = Variação das dívidas de curto prazo da empresa $i$ , no período $t$ ; e |
| $Assets_{it-1}$    | = Ativo Total da empresa $i$ , no período anterior a $t$ .                |

As variáveis representativas da parcela não discricionária ( $X_{kit}$ ) terão por base os modelos descritos a seguir.

**Modelo 1 – Healy (Healy, 1985):**

O modelo proposto por Healy (1985) não estabelece nenhum determinante da parcela não discricionária dos *accruals* e, portanto, os *accruals* totais ( $Wc\_Acc_{it}$ ) representam toda parcela discricionária (*Discretionary Accrual Proxy – DAP*):

$$DAP_{1it} = Wc\_Acc_{it}$$

**Modelo 2 – DD (Dechow e Dichev, 2002):**

$$\Delta WC_{it} = \alpha + \beta_1 X_{1it} + \beta_2 X_{2it} + \beta_3 X_{3it} + \varepsilon_{2it} \quad (3)$$

Onde:

$X_{1it} = CFO_{it-1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t-1$ ;  
 $X_{2it} = CFO_{it}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t$ ;  
 $X_{3it} = CFO_{it+1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t+1$ .

$$DAP_{2it} = \varepsilon_{2it}$$

**Modelo 3 – Jones (Jones, 1991):**

$$Wc\_Acc_{it} = \alpha + \beta_1 X_{1it} + \beta_2 X_{2it} + \varepsilon_{3it} \quad (4)$$

Onde:

$X_{1it} = \Delta Rev_{it}$  = Variação das Receitas da empresa  $i$ , no período  $t$ , dividida pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ );  
 $X_{2it} = PPE_{it}$  = Ativo Imobilizado da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ ).

$$DAP_{3it} = \varepsilon_{3it}$$

**Modelo 4 – JonenM (Dechow et al., 1995):**

$$Wc\_Acc_{it} = \alpha + \beta_1 (X_{1it} - X_{2it}) + \beta_2 X_{3it} + \varepsilon_{4it} \quad (5)$$

Cuja diferença, em relação ao modelo Jones original, é representada pela variável  $X_{2it}$ :

$X_{1it} = \Delta Rev_{it}$  = Variação das Receitas da empresa  $i$ , no período  $t$ , dividida pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ );  
 $X_{2it} = \Delta Rec_{it}$  = variação nos recebíveis da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ );  
 $X_{3it} = PPE_{it}$  = Ativo Imobilizado da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ ).

$$DAP_{4it} = \varepsilon_{4it}$$

**Modelo 5: McNichols (2002) (MN):**

$$\Delta WC_{it} = \alpha + \beta_1 X_{1it} + \beta_2 X_{2it} + \beta_3 X_{3it} + \beta_4 X_{4it} + \beta_5 X_{5it} + \varepsilon_{5it} \quad (6)$$

Onde:

|                             |  |
|-----------------------------|--|
| $X_{1it} = \Delta Rev_{it}$ | = Variação das Receitas da empresa $i$ , no período $t$ , dividida pelos Ativos Totais da empresa $i$ no período anterior ( $t-1$ ); |
| $X_{2it} = PPE_{it}$        | = Ativo Imobilizado da empresa $i$ , no período $t$ , dividido pelos Ativos Totais da empresa $i$ no período anterior ( $t-1$ ).     |
| $X_{3it} = CFO_{it-1}$      | = Fluxo de Caixa Operacional da empresa $i$ no período $t-1$ ;   |
| $X_{4it} = CFO_{it}$        | = Fluxo de Caixa Operacional da empresa $i$ no período $t$ ;   |
| $X_{5it} = CFO_{it+1}$      | = Fluxo de Caixa Operacional da empresa $i$ no período $t+1$ ;   |

$$DAP_{5it} = \varepsilon_{5it}$$

### 3.3.3. Procedimentos Metodológicos

Os procedimentos metodológicos serão realizados com base em dois contextos. Primeiramente (**Contexto 1**), a especificação dos modelos é avaliada com base em seleções aleatórias de observações firma-trimestre, representando gerenciamento de resultados e subsequentes reversões, sem a simulação de gerenciamento de resultados. No **Contexto 2**, são incluídas parcelas de gerenciamento gerados artificialmente (*accruals* discricionários), assim como suas reversões. Para efeito de comparabilidade com trabalhos anteriores (Dechow, Sloan & Sweeney (1995); Dechow et al. (2012)) utiliza-se a proporção de 0.1% da amostra para seleção das observações do **Contexto 1**. O **Contexto 2** conta, com avaliações baseadas em dois níveis de inclusão artificial do gerenciamento: 1% e 2% da Variação dos Ativos Totais. Os procedimentos específicos para cada contexto e cenário são descritos a seguir.

#### 3.3.4. Etapas para o Contexto 1

Os testes do Contexto 1 são realizados com base nas seguintes etapas:

1. Selecionam-se 0.1% das observações da amostra aleatoriamente. Para estas observações, à variável binária  $P_{it}$  designa-se o valor de 1. Para o restante da amostra,  $P_{it} = 0$ ;
2. Caso haja observações nos dois períodos imediatamente posteriores aos selecionados na etapa anterior, a estes designam-se  $PR1_{it} = 1$  (para o primeiro período subsequente) e  $PR2_{it} = 1$ , para o segundo. Para o restante da amostra, tem-se  $PR1_{it} = 0$  e  $PR2_{it} = 0$ ;
3. Conduz-se uma regressão com dados empilhados (*Pooled OLS – POLS*) para cada modelo descrito no item 1.2 utilizando toda a amostra;
4. Repetem-se as etapas 1, 2 e 3 1.000 (mil) vezes;
5. Registra-se o percentual de rejeições da hipótese nula (ausência de gerenciamento de resultados) ao nível de 5% para testes uni caudais. Para os testes com base na distribuição F, utiliza-se um nível de 10% condicionado à direção na qual a restrição linear é rejeitada, o que equivale a um teste uni caudal a 5%.

#### 3.3.5. Etapas para o Contexto 2

Os testes de poder dos modelos são realizados com base na análise de dois aspectos que o afetam: a variação na proporção das reversões; e o tamanho da amostra com gerenciamento induzido. O primeiro aspecto será testado com base nas seguintes etapas:

1. Selecionam-se 0.1% das observações da amostra aleatoriamente. Para estas observações, à variável binária  $P_{it}$  designa-se o valor de 1. Para o restante da amostra,  $P_{it} = 0$ ;

2. A estas são incluídas parcelas de gerenciamento gerados artificialmente (*accruals* discricionários) equivalentes a 1% e 2% (dependendo do cenário) da variação dos Ativos Totais;
3. A partir da amostra da etapa 1, selecionam-se os dois períodos subsequentes ( $PR1_{it} = 1$  e  $PR2_{it} = 1$ , caso haja observações). Consideram-se 11 cenários nos quais o gerenciamento de resultados induzido na etapa 2 é revertido em incrementos de 10%, de 0% (ou seja, sem reversão) a 100% (ou seja, reversão completa) neste ano subsequente;
4. Conduz-se uma regressão (*POLS*) para cada modelo descrito no item 1.2 utilizando toda a amostra;
5. Repetem-se 1,000 (mil) vezes as etapas 1, 2, 3 e 4;
6. Com base no percentual de rejeições da hipótese nula (ausência de gerenciamento de resultados) ao nível de 5% para testes uni caudais. Para os testes com base na distribuição F, utiliza-se um nível de 10% condicionado à direção na qual a restrição linear é rejeitada, o que equivale a um teste uni caudal a 5%.

O segundo aspecto analisado tem por base as seguintes etapas:

1. Selecionam-se 0.1% das observações da amostra aleatoriamente. Para estas observações, à variável binária  $P_{it}$  designa-se o valor de 1. Para o restante da amostra,  $P_{it} = 0$ ;
2. A estas são incluídas parcelas de gerenciamento gerados artificialmente (*accruals* discricionários) equivalentes a 1% e 2% (dependendo do cenário) da Variação dos Ativos Totais;
3. A partir da amostra da etapa 1, selecionam-se os dois períodos subsequentes ( $PR1_{it} = 1$ , caso haja observações). Para estas observações, efetuam-se reversões do gerenciamento induzido na etapa 2, igual em magnitude, mas oposta em sinal (ou seja, 100% de reversão);
4. Conduz-se uma regressão (*POLS*) para cada modelo descrito no item 1.2 utilizando toda a amostra;
5. Repetem-se 1,000 (mil) vezes as etapas 1, 2, 3 e 4;
6. Com base no percentual de rejeições da hipótese nula (ausência de gerenciamento de resultados) ao nível de 5% para testes uni caudais. Para os testes com base na distribuição F, utiliza-se um nível de 10% condicionado à direção na qual a restrição linear é rejeitada, o que equivale a um teste uni caudal a 5%.

Para todas as regressões do trabalho, utiliza-se a matriz HAC (*heteroskedasticity and autocorrelation consistent*). Testes adicionais foram realizados considerando amostras de gerenciamento induzido de 1%, 10% e 20%.



### 3.4. Análise dos Resultados

#### 3.4.1. Estatísticas Descritivas

A Tabela 1 apresenta algumas estatísticas descritivas das variáveis dependentes utilizadas nos modelos. Cada variável apresenta 7.866 observações firma-trimestre.

**Tabela 1:** Estatísticas descritivas das variáveis dependentes.

| Estat.    | <i>PPE</i> | $\Delta Rev$ | $\Delta Rec$ | <i>CFO</i> |
|-----------|------------|--------------|--------------|------------|
| N. Obs.   | 7866       | 7866         | 7866         | 7866       |
| Média     | 0.2350     | 0.0183       | 0.0033       | 0.0114     |
| Desvio P. | 0.2127     | 0.1597       | 0.0432       | 0.0915     |
| Mínimo    | 0.0006     | -0.4316      | -0.1141      | -0.3430    |
| 25%       | 0.0408     | -0.0115      | -0.0087      | -0.0268    |
| 50%       | 0.1978     | 0.0041       | 0.0005       | 0.0163     |
| 75%       | 0.3493     | 0.0247       | 0.0101       | 0.0612     |
| Máximo    | 0.9094     | 1.2846       | 0.2929       | 0.2658     |

**Obs.:** estatísticas descritivas das variáveis dependentes dos modelos testados na pesquisa, calculadas da seguinte forma:

$PPE_{it}$  = Ativo Imobilizado da empresa *i*, no período *t*, dividido

pelos Ativos Totais da empresa *i* no período anterior (*t-1*).

$\Delta Rev_{it}$  = Variação das Receitas da empresa *i*, no período *t*, dividida pelos Ativos Totais da empresa *i* no período anterior (*t-1*);

$\Delta Rec_{it}$  = variação nos recebíveis da empresa *i*, no período *t*, dividido pelos Ativos Totais da empresa *i* no período anterior (*t-1*).

$CFO_{it}$  = Fluxo de Caixa Operacional da empresa *i* no período *t*.

**Fonte:** Dados da pesquisa.

A Tabela 2 apresenta as estatísticas descritivas da variável independente utilizada nos modelos testados (*accruals* de capital de giro (*Wc\_Acc*)). Através do Painel A, percebe-se que a média desta variável apresenta sinal positivo, apesar de seu valor se aproximar de zero, o que sugere que as empresas da amostra cresceram ligeiramente no período analisado. A distribuição dos valores, conforme análise dos percentis, indica uniformidade e, portanto, relativa simetria.

**Tabela 2:** Estatísticas descritivas da variável independente.

| Painel A: Estatísticas da variável independente utilizada nos modelos |        |                 |                 |         |         |        |        |
|---|--------|-----------------|-----------------|---------|---------|--------|--------|
|   | Média  | Desvio P.       | 5%              | 25%     | 50%     | 75%    | 95%    |
| $Wc\_Acc_t$   | 0.0024 | 0.0641          | -0.0793         | -0.0199 | -0.0002 | 0.0196 | 0.0865 |
| Painel B: Correlações de Pearson                                      |        |                 |                 |         |         |        |        |
|   | $LL_t$ | $Wc\_Acc_{t+1}$ | $Wc\_Acc_{t+2}$ |         |         |        |        |
| $Wc\_Acc_t$   | 0.1800 | -0.0710         | -0.0421         |         |         |        |        |

**Obs.:** estatísticas descritivas dos *accruals* de capital de giro (*Wc\_Acc*), calculado da seguinte forma:

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}$$

Onde:

$\Delta CA_{it}$  = Variação do Ativo Circulante da empresa *i*, no período *t*;

$\Delta CL_{it}$  = Variação do Passivo Circulante da empresa *i*, no período *t*;

$\Delta Cash_{it}$  = Variação do Caixa da empresa *i*, no período *t*;

$\Delta STD_{it}$  = Variação das dívidas de curto prazo da empresa *i*, no período *t*;

$Assets_{it-1}$  = Ativo Total da empresa *i*, no período anterior a *t*;

$CFO_{it-1}$  = Fluxo de Caixa Operacional da empresa *i* no período *t-1*;

---

$CFO_{it}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t$ ;  
 $CFO_{it+1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t+1$ ;

---

**Fonte:** Dados da pesquisa.

O Pannel B da Tabela 2 expõe correlações entre a variável representativa dos *accruals* de capital de giro ( $Wc\_Acc_{it}$ ) e o Lucro Líquido no mesmo período, assim como em relação a ela mesma em períodos subsequentes. Corroborando os resultados encontrados por Dechow et al. (2012), a correlação entre os *accruals* de capital de giro e o Lucro Líquido foi da ordem de 0,18 e, da mesma forma, indica o primeiro representa um fator relevante em relação ao segundo. No que se refere às autocorrelações, apesar do sinal negativo (-0,0710 e -0,0421 em relação a  $Wc\_Acc_{t+1}$  e  $Wc\_Acc_{t+2}$ , respectivamente), os resultados estão próximos de zero, o que implica dizer que os *accruals* de capital de giro não apresentam tendência clara de reversão ou persistência, em média.

**Tabela 3:** Estatísticas descritivas dos *accruals* de capital de giro para decis formados no desempenho dos lucros.

| Decil | Média   |         |         | Desvio Padrão |        |        |
|-------|---------|---------|---------|---------------|--------|--------|
|       | $t$     | $t+1$   | $t+2$   | $t$           | $t+1$  | $t+2$  |
| 1     | -0.0098 | -0.0015 | -0.0017 | 0.0721        | 0.0850 | 0.0803 |
| 2     | -0.0072 | -0.0054 | 0.0010  | 0.0590        | 0.0666 | 0.0748 |
| 3     | -0.0042 | 0.0022  | -0.0049 | 0.0559        | 0.0525 | 0.0566 |
| 4     | 0.0025  | 0.0032  | 0.0032  | 0.0549        | 0.0560 | 0.0564 |
| 5     | 0.0039  | 0.0012  | -0.0021 | 0.0464        | 0.0526 | 0.0543 |
| 6     | 0.0012  | -0.0010 | -0.0011 | 0.0442        | 0.0491 | 0.0515 |
| 7     | 0.0017  | 0.0030  | 0.0044  | 0.0478        | 0.0568 | 0.0661 |
| 8     | 0.0029  | 0.0026  | 0.0076  | 0.0564        | 0.0600 | 0.0628 |
| 9     | 0.0069  | 0.0080  | 0.0084  | 0.0625        | 0.0697 | 0.0643 |
| 10    | 0.0265  | 0.0118  | 0.0088  | 0.1092        | 0.0798 | 0.0649 |

**Obs.:** estatísticas descritivas dos *accruals* de capital de giro ( $Wc\_Acc$ ) com base em decis formados com base no desempenho do Lucro Líquido ( $LL_{it}/Assets_{it-1}$ ). Os *accruals* de capital de giro são calculados da seguinte forma:

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}$$

Onde:

$\Delta CA_{it}$  = Variação do Ativo Circulante da empresa  $i$ , no período  $t$ ;  
 $\Delta CL_{it}$  = Variação do Passivo Circulante da empresa  $i$ , no período  $t$ ;  
 $\Delta Cash_{it}$  = Variação do Caixa da empresa  $i$ , no período  $t$ ;  
 $\Delta STD_{it}$  = Variação das dívidas de curto prazo da empresa  $i$ , no período  $t$ ;  
 $Assets_{it-1}$  = Ativo Total da empresa  $i$ , no período anterior a  $t$ ;  
 $CFO_{it-1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t-1$ ;  
 $CFO_{it}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t$ ;  
 $CFO_{it+1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t+1$ ;

---

**Fonte:** Dados da pesquisa.

A Tabela 3 apresenta a média e o desvio-padrão dos *accruals* de capital de giro em três períodos ( $Wc\_Acc_{it}$ ,  $Wc\_Acc_{it+1}$  e  $Wc\_Acc_{it+2}$ ) distribuídos em decis formados com base no desempenho do Lucro Líquido ( $LL_{it}$ ). Diferentemente dos resultados encontrados por Dechow et al. (2012), não se percebe a mesma tendência clara entre as mesmas variáveis, ou seja, não se apresenta a mesma correlação positiva entre os *accruals* e a performance dos lucros. Percebe-se uma tendência de aumento nos valores dos *accruals* de capital de giro no período  $t$  entre o primeiro e quinto decil, uma redução no sexto decil, iniciando uma nova tendência de aumento, culminando em um aumento substancial entre o nono e décimo decil. Com relação aos períodos  $t+1$  e  $t+2$ , não se detectam tendências relevantes.

Quando se analisa o comportamento do desvio-padrão médio dos *accruals* de capital de giro no período  $t$ , conforme Tabela 3, nota-se um padrão de redução entre o primeiro e sexto decil, seguido de uma tendência de aumento a partir deste. Ressalta-se o aumento substancial no valor do desvio-padrão entre o nono e décimo decil. Com relação ao período  $t + 1$ , a principal diferença se mostra no primeiro e último decil: há um aumento no valor médio no primeiro decil e uma redução considerável no décimo. As médias para  $t + 2$  são mais homogêneas, apresentando reduções no primeiro e último decil, em relação a  $t + 1$ .

### 3.5. Resultados dos Testes

#### 3.5.1. Testes de Especificidade para Gerenciamento de Resultados em Amostras Aleatórias

A Tabela 4 relata os coeficientes, estatísticas  $t$  e  $R$ -quadrado ajustado médios das 1.000 regressões com simulações de gerenciamento de resultados atribuídos de forma aleatória para cada um dos modelos de gerenciamento de resultados testados na pesquisa. Como esperado, as médias dos parâmetros estimados para as variáveis de particionamento ( $P_{it}$ ,  $PR1_{it}$ ,  $PR2_{it}$ ) apresentam valores próximos de zero, assim como suas estatísticas  $t$  médias, em todos os modelos.

**Tabela 4:** Média dos coeficientes, estatística  $t$  e  $R$ -quadrado ajustado dos modelos.

| Modelo | Param.    | Coef.   | t-stat  | Adj. $R^2$ |
|--------|-----------|---------|---------|------------|
| Healy  | $\beta_1$ | 0.0054  | 0.2571  | 0.0052%    |
|        | $\beta_2$ | -0.0001 | -0.0795 |            |
|        | $\beta_3$ | 0.0012  | 0.0053  |            |
|        | $\alpha$  | 0.0024  | 3.6848  |            |
| DD     | $\beta_1$ | 0.0048  | 0.2535  | 2.2535%    |
|        | $\beta_2$ | -0.0002 | -0.0718 |            |
|        | $\beta_3$ | 0.0009  | 0.0062  |            |
|        | $\beta_4$ | 0.1107  | 4.1883  |            |
|        | $\beta_5$ | -0.1662 | -4.3326 |            |
|        | $\beta_6$ | 0.0090  | 0.4879  |            |
|        | $\alpha$  | 0.0029  | 4.2755  |            |
| Jones  | $\beta_1$ | 0.0054  | 0.2961  | 14.6087%   |
|        | $\beta_2$ | 0.0004  | -0.0298 |            |
|        | $\beta_3$ | 0.0022  | 0.1256  |            |
|        | $\beta_4$ | -0.0002 | -0.0631 |            |
|        | $\beta_5$ | 0.1536  | 11.3770 |            |
|        | $\alpha$  | -0.0003 | -0.3285 |            |
| JonesM | $\beta_1$ | 0.0062  | 0.3345  | 9.4369%    |
|        | $\beta_2$ | 0.0001  | -0.0599 |            |
|        | $\beta_3$ | 0.0019  | 0.0814  |            |
|        | $\beta_4$ | 0.0070  | 1.8896  |            |
|        | $\beta_5$ | 0.1439  | 8.6715  |            |
|        | $\alpha$  | -0.0014 | -1.2842 |            |
| MN     | $\beta_1$ | 0.0049  | 0.2901  | 17.0215%   |

|           |         |         |
|-----------|---------|---------|
| $\beta_2$ | 0.0003  | -0.0236 |
| $\beta_3$ | 0.0019  | 0.1270  |
| $\beta_4$ | -0.0011 | -0.3146 |
| $\beta_5$ | 0.1553  | 11.9795 |
| $\beta_6$ | 0.1358  | 6.2478  |
| $\beta_7$ | -0.1764 | -5.8727 |
| $\beta_8$ | 0.0042  | 0.2624  |
| $\alpha$  | 0.0002  | 0.2240  |

**Obs.:** Médias dos coeficientes e suas estatísticas t e R-quadrado ajustado das mil regressões realizadas para cada modelo em um cenário no qual 0,1% da amostra apresenta  $P_{it} = 1$ , sem a inclusão de gerenciamento. Os parâmetros apresentados são definidos conforme modelos:

**Healy:**  $Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$ ;

**DD:**  $Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \beta_4 CFO_{it-1} + \beta_5 CFO_{it} + \beta_6 CFO_{it+1} + \varepsilon_{it}$ ;

**Jones:**  $Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \beta_4 PPE_{it} + \beta_5 \Delta Rev_{it} + \varepsilon_{it}$ ;

**JonesM:**  $Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \beta_4 PPE_{it} + \beta_5 (\Delta Rev_{it} - \Delta Rec_{it}) + \varepsilon_{it}$ ;

**MN:**  $Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \beta_4 PPE_{it} + \beta_5 \Delta Rev_{it} + \beta_6 CFO_{it-1} + \beta_7 CFO_{it} + \beta_8 CFO_{it+1} + \varepsilon_{it}$ ;

**Fonte:** Dados da pesquisa.

De forma geral, os coeficientes dos parâmetros das variáveis explicativas dos modelos testados apresentam os valores esperados: positivos e significantes para a Variação das Receitas ( $\Delta Rev_{it}$ ) e Fluxo de Caixa Defasado ( $CFO_{it-1}$ ); positivos para o Fluxos de Caixa Futuro ( $CFO_{it+1}$ ); negativos e significantes para o Fluxos de Caixa Contemporâneo ( $CFO_{it}$ ); e negativos para o Imobilizado ( $PPE_{it}$ ). Exceção ocorre para o Imobilizado no modelo Jones modificado (JonesM), com sinal positivo, em média, para o coeficiente.

Com relação ao R-quadrado ajustado, comparando-se com os resultados apurados por Dechow et al. (2012), os valores médios para os modelos Healy, Jones e JonesM são semelhantes, apenas ligeiramente superiores. A grande diferença se apresenta nos modelos DD e MN, com valores médios inferiores na ordem de 15 e 10%, respectivamente.

A Tabela 5 apresenta o percentual de rejeição das hipóteses estatísticas (três para cada modelo) após mil regressões em um cenário no qual 0,1% da amostra apresenta  $P_{it} = 1$ , de forma aleatória e sem a inclusão de gerenciamento. Utilizou-se o teste binomial para determinar a especificidade dos modelos, ou seja, os resultados dos testes binomiais indicam se o percentual de rejeição das hipóteses testadas equivale, estatisticamente, ao alfa especificado (neste caso, 5%).

**Tabela 5:** percentual de rejeição das hipóteses estatísticas após mil regressões.

| Modelo | Teste (5%)                        | Signif. (+) | Signif. (-) |
|--------|-----------------------------------|-------------|-------------|
| Healy  | $\beta_1 = 0$                     | 4.60%       | 2.60%*      |
|        | $\beta_1 - \beta_2 = 0$           | 10.80%***   | 4.90%       |
|        | $\beta_1 - \beta_2 - \beta_3 = 0$ | 10.90%***   | 6.10%       |
| DD     | $\beta_1 = 0$                     | 5.20%       | 2.70%*      |
|        | $\beta_1 - \beta_2 = 0$           | 10.50%***   | 5.80%       |
|        | $\beta_1 - \beta_2 - \beta_3 = 0$ | 9.90%***    | 6.30%       |
| Jones  | $\beta_1 = 0$                     | 5.70%       | 2.90%*      |
|        | $\beta_1 - \beta_2 = 0$           | 10.50%***   | 5.10%       |
|        | $\beta_1 - \beta_2 - \beta_3 = 0$ | 9.70%***    | 6.60%       |
| JonesM | $\beta_1 = 0$                     | 5.80%       | 2.70%*      |
|        | $\beta_1 - \beta_2 = 0$           | 11.10%***   | 5.10%       |
|        | $\beta_1 - \beta_2 - \beta_3 = 0$ | 10.00%***   | 6.30%       |
| MN     | $\beta_1 = 0$                     | 6.90%       | 2.80%*      |

|  |                                   |          |       |
|--|-----------------------------------|----------|-------|
|  | $\beta_1 - \beta_2 = 0$           | 10.30%** | 6.40% |
|  | $\beta_1 - \beta_2 - \beta_3 = 0$ | 8.80%*   | 7.80% |

**Obs. 1:** tabela apresenta o percentual de rejeição das hipóteses estatísticas após mil regressões para cada modelo em um cenário no qual 0,1% da amostra apresenta  $P_{it} = 1$ , sem a inclusão de gerenciamento;

**Obs. 2:** \*, \*\* e \*\*\* significativamente diferente das taxas de rejeição especificadas a 1%, 5% e 10%, com base em teste binomial a 5%;

**Obs. 3:** Os parâmetros apresentados são definidos conforme modelos:

**Healy:**  $Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$ ;

**DD:**  $Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \beta_4 CFO_{it-1} + \beta_5 CFO_{it} + \beta_6 CFO_{it+1} + \varepsilon_{it}$ ;

**Jones:**  $Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \beta_4 PPE_{it} + \beta_5 \Delta Rev_{it} + \varepsilon_{it}$ ;

**JonesM:**  $Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \beta_4 PPE_{it} + \beta_5 (\Delta Rev_{it} - \Delta Rec_{it}) + \varepsilon_{it}$ ;

**MN:**  $Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \beta_4 PPE_{it} + \beta_5 \Delta Rev_{it} + \beta_6 CFO_{it-1} + \beta_7 CFO_{it} + \beta_8 CFO_{it+1} + \varepsilon_{it}$ ;

**Fonte:** Dados da pesquisa.

De forma geral, os resultados da Tabela 5 sugerem que todos os modelos são bem especificados para o teste  $\beta_1 = 0$ , quando  $\beta_1$  é positivo. Quando se testa  $\beta_1 < 0$ , por outro lado, os resultados apurados apontam problemas de especificidade para todos os modelos (com rejeição a 10% no teste binomial).

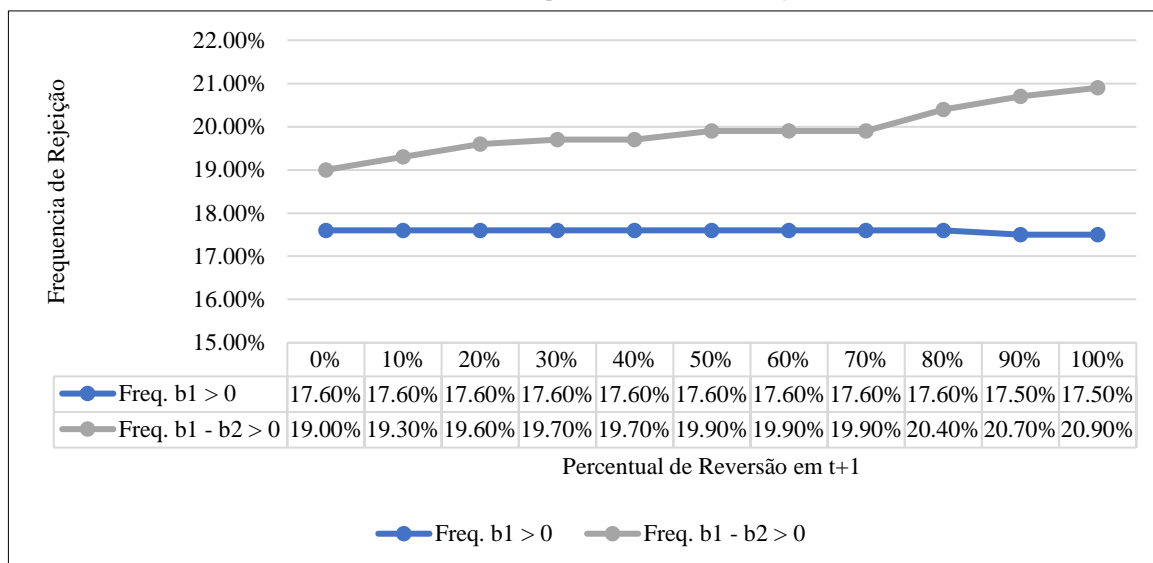
Com relação aos testes  $\beta_1 - \beta_2 = 0$  e  $\beta_1 - \beta_2 - \beta_3 = 0$ , a Tabela 5 indica problemas de especificação em todos os modelos, quando se trata de gerenciamento positivo. Em contrapartida, os mesmos testes aplicados a gerenciamentos negativos indicam que todos os modelos são bem especificados.

### 3.5.2. Poder dos Testes para Gerenciamento de Resultados Usando Simulações com Gerenciamento Induzido

O objetivo ao induzir o gerenciamento de resultados em amostras aleatórias são os mesmos destacados por Dechow, Sloan e Sweeney (1995) e Dechow et al. (2012). Em primeiro lugar, estes testes ilustram a eficácia de modelos específicos na detecção do gerenciamento de resultados, em se tratando de magnitudes conhecidas. Em segundo lugar, são úteis para ilustrar os ganhos de poder resultantes da modelação de reversões de *accruals*, incluindo cenários em que o pesquisador tem informações relativamente fracas no que tange ao momento das reversões do gerenciamento.

A Figura 6 apresenta a relação entre a taxa de rejeição das hipóteses ( $\beta_1 > 0$  e  $\beta_1 - \beta_2 > 0$ , a 5%) e o percentual de reversão do gerenciamento induzido no ano subsequente (variando de 0% – ausência de reversão – a 100% – reversão completa do gerenciamento induzido no ano anterior). A base para se estabelecer se a inclusão de uma variável representativa da reversão do gerenciamento promove ganhos no modelo, é o valor da frequência de rejeição apurado para a hipótese  $\beta_1 > 0$ , ou seja, a frequência de rejeição da hipótese de gerenciamento positivo, quando não se modela a sua reversão.

Os resultados apresentados na Figura 6 se basearam em testes para amostras com sucessivas induções de gerenciamento de resultados, equivalente a 1% da Variação dos Ativos Totais. Os percentuais de rejeição das hipóteses representam a fração das mil regressões para as quais a hipótese testada foi significativa a 5%. Utilizou-se o modelo **Healy** para os testes, seguindo metodologia proposta por Dechow et al. (2012).

**Figura 6:** Gerenciamento induzido equivalente a 1% da Variação dos Ativos Totais.

Obs.: A figura apresenta o poder de detecção dos testes para uma amostra com gerenciamento de resultados positivo induzido (equivalente a 1% da Variação dos Ativos Totais) e parcialmente revertido no período subsequente. Todos os testes ocorrem em um contexto de indução aleatória de gerenciamento para 1% da amostra de e um teste uni caudal a 5%.

Os percentuais de rejeição das hipóteses representam a proporção das mil regressões para as quais a hipótese testada foi significativa (teste uni caudal a 5%).

Todos os testes utilizam o modelo **Healy**, conforme segue:

$$Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it};$$

Onde:

$Wc\_Acc_{it}$  = Proxy dos *accruals* totais da empresa  $i$ , no período  $t$ ;  
 $P_{it}$  = Variável *dummy* que assume valor 1 para observações com gerenciamento e 0, caso contrário;  
 $PR1_{it}$  = Variável *dummy* que assume valor 1 para observações com reversão do gerenciamento no ano subsequente à indução e 0, caso contrário;

Por sua vez, o  $Wc\_Acc_{it}$  pode assumir duas configurações:

$$Wc\_Acc_{it} = ((\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}) + Gerenciamento\ Induzido_{it}$$

Para 1% das observações firma-trimestre, aleatoriamente, ou:

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}$$

Para as demais observações, onde:

$\Delta CA_{it}$  = Variação do Ativo Circulante da empresa  $i$ , no período  $t$ ;  
 $\Delta CL_{it}$  = Variação do Passivo Circulante da empresa  $i$ , no período  $t$ ;  
 $\Delta Cash_{it}$  = Variação do Caixa da empresa  $i$ , no período  $t$ ;  
 $\Delta STD_{it}$  = Variação das dívidas de curto prazo da empresa  $i$ , no período  $t$ ; e  
 $Assets_{it-1}$  = Ativo Total da empresa  $i$ , no período anterior a  $t$ .

**Fonte:** Dados da pesquisa.

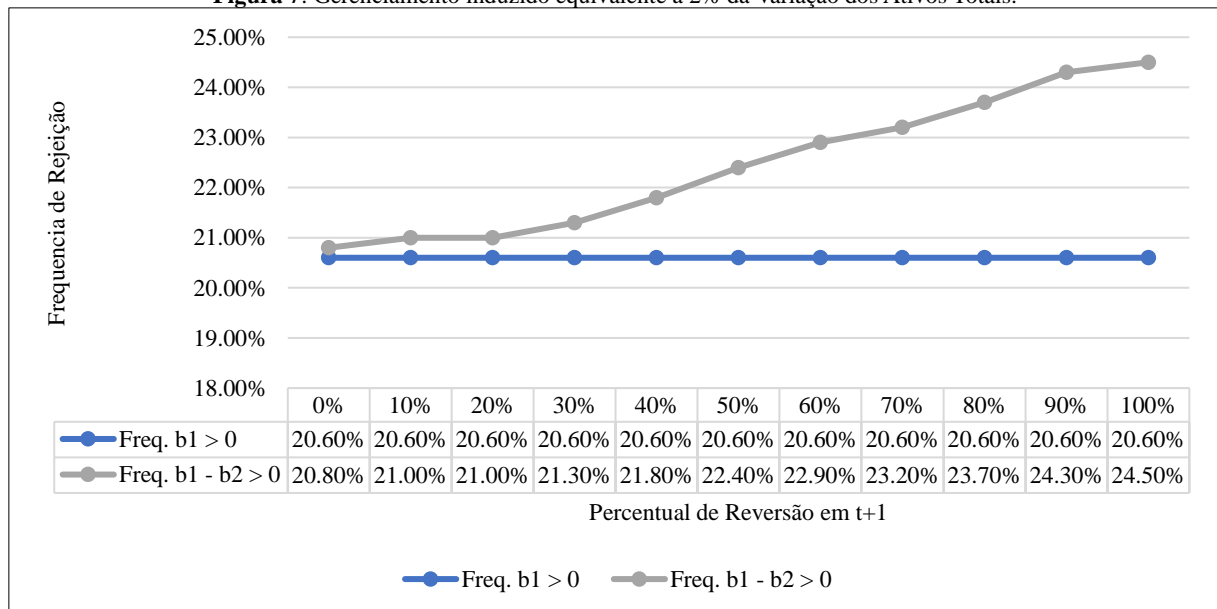
Com base na Figura 6, tem-se que a referência para análise do ganho de poder dos testes, quando se inclui reversão no modelo de detecção, é de 17,6% (frequência de rejeição quando não há reversão). Pode-se notar pelos resultados apresentados que há um ganho de poder nos testes quando se inclui a variável representativa de reversão, mesmo quando esta não existe. Tal ganho representa um mínimo de 1,4% (ausência de reversão) e um máximo de

2,4% (reversão completa), aumentando de acordo com a amplitude do percentual de reversão do gerenciamento induzido.

Os resultados apresentados na Figura 7 se basearam em testes para amostras com sucessivas induções de gerenciamento de resultados, equivalente a 2% da Variação dos Ativos Totais. Os percentuais de rejeição das hipóteses representam a fração das mil regressões para as quais a hipótese testada foi significativa a 5%. Utilizou-se o modelo **Healy** para os testes, seguindo metodologia proposta por Dechow et al. (2012).

Com relação aos resultados apurados para o contexto apresentado na Figura 6, destaca-se uma proximidade maior no poder dos testes para o contexto em que não há reversões (de 1,4%, para o contexto anterior, para apenas 0,2%, no contexto sob análise) e um distanciamento maior no contexto de reversões totais (de 2,4% para 3,9%). Esta tendência se reflete de acordo com a amplitude do percentual de reversão do gerenciamento induzido, sendo observado, porém, um descolamento em nível superior a partir do ponto em que as reversões representam 20% das inclusões.

**Figura 7:** Gerenciamento induzido equivalente a 2% da Variação dos Ativos Totais.



Obs.: A figura apresenta o poder de detecção dos testes para uma amostra com gerenciamento de resultados positivo induzido (equivalente a 2% da Variação dos Ativos Totais) e parcialmente revertido no período subsequente. Todos os testes ocorrem em um contexto de indução aleatória de gerenciamento para 1% da amostra de e um teste uni caudal a 5%.

Os percentuais de rejeição das hipóteses representam a proporção das mil regressões para as quais a hipótese testada foi significativa (teste uni caudal a 5%).

Todos os testes utilizam o modelo **Healy**, conforme segue:

$$Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it};$$

Onde:

$Wc\_Acc_{it}$  = proxy dos *accruals* totais da empresa  $i$ , no período  $t$ ;  
 $P_{it}$  = variável *dummy* que assume valor 1 para observações com gerenciamento e 0, caso contrário;  
 $PR1_{it}$  = variável *dummy* que assume valor 1 para observações com reversão do gerenciamento no ano subsequente à indução e 0, caso contrário;

Por sua vez, o  $Wc\_Acc_{it}$  pode assumir duas configurações:

$$Wc\_Acc_{it} = ((\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}) + Gerenciamento\ Induzido_{it}$$

Para 1% das observações firma-trimestre, aleatoriamente, ou:

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}$$


Para as demais observações, onde:

|                    |   |
|--------------------|---|
| $\Delta CA_{it}$   | = variação no Ativo Circulante da empresa $i$ , no período $t$ ;          |
| $\Delta CL_{it}$   | = variação no Passivo Circulante da empresa $i$ , no período $t$ ;        |
| $\Delta Cash_{it}$ | = variação no Caixa da empresa $i$ , no período $t$ ;                     |
| $\Delta STD_{it}$  | = variação nas dívidas de curto prazo da empresa $i$ , no período $t$ ; e |
| $Assets_{it-1}$    | = Ativo Total da empresa $i$ , no período anterior a $t$ .                |

**Fonte:** Dados da pesquisa.

A Figura 8 apresenta o poder de detecção dos testes para uma amostra com gerenciamento de resultados positivo induzido (equivalente a 2% da Variação dos Ativos Totais) e parcialmente revertido no período subsequente. Todos os testes ocorrem em um contexto de indução aleatória de gerenciamento para parcelas da amostra que variam entre 1% e 10%, com incrementos de 1%. Os percentuais de rejeição das hipóteses representam a proporção das mil regressões para as quais a hipótese testada foi significativa (teste uni caudal a 5%), utilizando o modelo **Healy** (Healy, 1985), conjuntamente às variáveis *dummy*, objetos dos testes.

**Figura 8:** Frequência de Rejeição de Ausência de Gerenciamento em Relação ao Tamanho da Amostra.



Obs.: A figura apresenta o poder de detecção dos testes para uma amostra com gerenciamento de resultados positivo induzido (equivalente a 2% da Variação dos Ativos Totais) e parcialmente revertido no período subsequente. Todos os testes ocorrem em um contexto de indução aleatória de gerenciamento para parcelas da amostra que variam entre 1% e 10%, com incrementos de 1%.

Os percentuais de rejeição das hipóteses representam a proporção das mil regressões para as quais a hipótese testada foi significativa (teste uni caudal a 5%).

Todos os testes utilizam o modelo **Healy**, conforme segue:

$$Wc\_Acc_{it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it};$$

Onde:

|                |   |
|----------------|---|
| $Wc\_Acc_{it}$ | = proxy dos <i>accruals</i> totais da empresa $i$ , no período $t$ ;  |
| $P_{it}$       | = variável <i>dummy</i> que assume valor 1 para observações com gerenciamento e 0, caso contrário;  |
| $PR1_{it}$     | = variável <i>dummy</i> que assume valor 1 para observações com reversão do gerenciamento no ano subsequente à indução e 0, caso contrário; |

Por sua vez, o  $Wc\_Acc_{it}$  pode assumir duas configurações:

$$Wc\_Acc_{it} = ((\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}) + Gerenciamento\ Induzido_{it}$$



Para parcelas que variam de 1% a 10% das observações firma-trimestre, de forma aleatória, ou:

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}$$

Para as demais observações, onde:

|                    |   |
|--------------------|---|
| $\Delta CA_{it}$   | = variação no Ativo Circulante da empresa $i$ , no período $t$ ;          |
| $\Delta CL_{it}$   | = variação no Passivo Circulante da empresa $i$ , no período $t$ ;        |
| $\Delta Cash_{it}$ | = variação no Caixa da empresa $i$ , no período $t$ ;                     |
| $\Delta STD_{it}$  | = variação nas dívidas de curto prazo da empresa $i$ , no período $t$ ; e |
| $Assets_{it-1}$    | = Ativo Total da empresa $i$ , no período anterior a $t$ .                |

---

**Fonte:** Dados da pesquisa.

Uma regra prática comum em testes de hipóteses é que o poder *ex-ante* de um teste deve ser de pelo menos 80% para ter a precisão necessária para fornecer inferências confiáveis (Aberson, 2019)). Nenhum dos testes da Figura 6 e Figura 7 atende a esta regra, uma vez que a maior taxa de rejeição relatada foi de 24,5%.

A Figura 8 apresenta os resultados de simulações que nos permite determinar o número de observações com  $P_{it} = 1$  necessárias para gerar uma taxa de rejeição de 80%. Para essas simulações induz-se um gerenciamento de resultados equivalente a 2% da Variação dos Ativos Totais e reversões de 100% no período subsequente. Para se atingir 80% de poder no teste  $t$  ( $\beta_1 > 0$ ), é necessário, no mínimo de 6% observações com gerenciamento induzido.

### 3.6. Considerações Finais

Uma característica fundamental do processo baseado em *accruals*, é que as distorções de geradas em um período devem ser revertidas em outro período subsequente. No caso de *accruals* de capital de giro, que normalmente duram menos de um ano, tais reversões geralmente ocorrem dentro de um ano ou mais a partir do evento original. Baseado nesta premissa, este trabalho utilizou a estrutura metodológica proposta por Dechow et al. (2012) para testar se esta é capaz de introduzir melhorias em termos de poder e especificidade dos modelos tradicionais de gerenciamento de resultados no contexto das empresas brasileiras de capital aberto.

O trabalho contou com dados de 282 empresas não financeiras com ações negociadas na B3 entre os anos de 2010 (quarto trimestre) e 2022 (quarto trimestre). Os dados utilizados foram retirados das Demonstrações Financeiras em frequência trimestral, representando um total de 7.866 observações firma-trimestre.

Os procedimentos metodológicos foram realizados com base em dois contextos. Primeiramente (**Contexto 1**), onde a especificação dos modelos foi avaliada com base em seleções aleatórias de observações firma-trimestre, representando gerenciamento de resultados e subseqüentes reversões, sem a simulação de gerenciamento de resultados.

No **Contexto 2**, foram incluídas parcelas de gerenciamento gerados artificialmente (*accruals* discricionários), assim como suas reversões. Para efeito de comparabilidade com trabalhos anteriores (Dechow, Sloan & Sweeney (1995); Dechow et al. (2012)) utilizou-se a proporção de 0.1% da amostra para seleção das observações do **Contexto 1**. O **Contexto 2** conta com avaliações baseadas em dois níveis de inclusão artificial do gerenciamento: 1% e 2% da Variação dos Ativos Totais.

De forma geral, os resultados apurados indicam que o poder dos testes dos modelos de gerenciamento de resultados baseados em *accruals* é baixo para gerenciamento de magnitudes plausíveis. Por exemplo, mesmo os testes mais poderosos, que incorporam reversões, rejeitam a hipótese nula de não haver gerenciamento de resultados em percentual menor do que 30% do total (mil regressões para cada teste) com gerenciamento de resultados igual a 1% da variação dos Ativos Totais, um tamanho de amostra de 1% das observações da amostra e um nível de teste de 5%.

Os testes para gerenciamento de resultados são suscetíveis a erros de especificação devido à omissão de determinantes correlacionados aos *accruals* não discricionários. Não há panaceia para este problema, porque os modelos de *accruals* não discricionários são rudimentares e os determinantes do gerenciamento de resultados estão frequentemente correlacionados com características econômicas que influenciam os *accruals* não discricionários.

## Referências

- Ball, R., & Shivakumar, L. (2006). The role of accruals in asymmetrically timely gain and loss recognition. *Journal of accounting research*, 44(2), 207-242.
- Collins, D. W., Pungaliya, R. S., & Vijh, A. M. (2017). The effects of firm growth and model specification choices on tests of earnings management in quarterly settings. *Accounting Review*, 92(2), 69–100. <https://doi.org/10.2308/accr-51551>
- Dechow, P. M. (1994). Accounting & Economics The role of accounting accruals. *Journal of Accounting and Economics*, 18, 3–42. [https://doi.org/10.1016/0165-4101\(94\)90016-7](https://doi.org/10.1016/0165-4101(94)90016-7)
- Dechow, P., & Dichev, I. D. (2002). The Quality of Accruals and Earnings: The Role of Accruals Estimation Errors. *The Accounting Review*, 77(2002), 35–59. <https://doi.org/10.2308/accr.2002.77.s-1.61>
- Dechow, P. M., Hutton, A. P., Kim, J. H., & Sloan, R. G. (2012). Detecting Earnings Management: A New Approach. *Journal of Accounting Research*, 50(2), 275–334. <https://doi.org/10.1111/j.1475-679X.2012.00449.x>
- Dechow, P. M., Richardson, S. A., & Tuna, I. (2003). Why Are Earnings Kinky? An Examination of the Earnings Management Explanation. *Review of Accounting Studies* 2003 8:2, 8(2), 355–384. <https://doi.org/10.1023/A:1024481916719>
- Dechow, P. M., Sloan, R. G., & Sweeney, A. P. (1995). Detecting Earnings Management. *The Accounting Review*, 70(2), 193–225. <https://doi.org/10.2307/248303>
- Francis, J., LaFond, R., Olsson, P., & Schipper, K. (2005). The market pricing of accruals quality. *Journal of accounting and economics*, 39(2), 295-327.
- Healy, P. M. (1985). The effect of bonus schemes on accounting decisions. *Journal of accounting and economics*, 7(1-3), 85-107.
- Höglund, H. (2012). Detecting earnings management with neural networks. *Expert Systems with Applications*, 39(10), 9564–9570. <https://doi.org/10.1016/j.eswa.2012.02.096>
- Jeter, D. C., & Shivakumar, L. (1999). Cross-sectional estimation of abnormal accruals using quarterly and annual data: effectiveness in detecting event-specific earnings management. *Accounting and Business Research*, 29(4), 299–319. <https://doi.org/10.1080/00014788.1999.9729590>
- Jones, J. J. (1991). Earnings Management During Import Relief Investigations. *Journal of Accounting Research*, 29(2), 193. <https://doi.org/10.2307/2491047>
- Kothari, S. P., Leone, A. J., & Wasley, C. E. (2005). Performance matched discretionary accrual measures. *Journal of Accounting and Economics*, 39(1), 163–197. <https://doi.org/10.1016/j.jacceco.2004.11.002>

- McNichols, M. F. (2000). Research design issues in earnings management studies. *Journal of Accounting and Public Policy* 19(4–5). [https://doi.org/10.1016/S0278-4254\(00\)00018-1](https://doi.org/10.1016/S0278-4254(00)00018-1)
- Sloan, R. G. (1999). Evaluating the reliability of current value estimates. *Journal of Accounting and Economics*, 26(1-3), 193-200.
- Wang, X., Zhang, J., & Zhang, W. S. (2012). the Role of Operating Cash Flow in Credit Rating: Investment-Grade Firms Vs. Speculative grade Firms. *Risk Governance and Control: Financial Markets & Institutions*, 2(2), 48–63.  
<https://doi.org/10.22495/rgev2i2art3>
- Wysocki, P. (2009). Assessing earnings and accruals quality: US and international evidence. *Unpublished working paper*. Cambridge: MIT Sloan School of Management.
- Xie, H. (2001). The Mispricing of Abnormal Accruals. *The Accounting Review*, 76(3), 357–373. <https://doi.org/10.2308/ACCR.2001.76.3.357>

#### 4. Explorando o Potencial das Técnicas de *Machine Learning* na Detecção de Gerenciamento de Resultados

##### *Exploring the Potential of Machine Learning Techniques in Earnings Management Detection*

###### **Resumo**

Este estudo investiga a aplicação de técnicas de *machine learning* na detecção de gerenciamento de resultados, superando as limitações dos modelos tradicionais baseados em *accruals*. Os modelos tradicionais enfrentam desafios de mensuração direta do gerenciamento de resultados e sofrem com a complexidade inerente aos *accruals*. O estudo propõe uma abordagem inovadora, utilizando algoritmos de *machine learning* para determinar períodos de manipulação dos *accruals* e suas reversões. Três etapas metodológicas são delineadas, incluindo treinamento de algoritmos, comparação de modelos tradicionais com modelos modificados pelas variáveis geradas pelos algoritmos e análise dos resultados das regressões. Os resultados revelam que as técnicas de *machine learning*, especialmente o *Decision Trees Classifier*, oferecem uma solução viável, aumentando significativamente o poder explicativo em comparação com os modelos tradicionais. Esta pesquisa destaca o potencial transformador das técnicas de *machine learning* na detecção precisa do gerenciamento de resultados nas práticas contábeis.

**Palavras-chave:** Gerenciamento de Resultados. *Accruals*. Inteligência artificial. *Machine Learning*.

###### **Abstract**

*This study explores the application of machine learning techniques in earnings management detection, overcoming limitations of traditional accrual-based models. Traditional models face challenges in directly measuring earnings management and grapple with the inherent complexity of accruals. The study proposes an innovative approach, utilizing machine learning algorithms to determine periods of accrual manipulation and their reversals. Three methodological stages are outlined, including algorithm training, comparison of traditional models with models modified by variables generated by algorithms, and analysis of regression results. The results reveal that machine learning techniques, especially the Decision Trees Classifier, offer a viable solution, significantly enhancing explanatory power compared to traditional models. This research highlights the transformative potential of machine learning techniques in precisely detecting earnings management practices in accounting.*

**Keywords:** *Earnings Management. Accruals. Artificial Intelligence. Machine Learning.*

## 4.1. Introdução

Uma grande parcela dos estudos contábeis visa analisar o gerenciamento de resultados em diversas situações, incluindo: antes das ofertas públicas iniciais (IPOs), durante dificuldades financeiras e em meio a mudanças nos padrões contábeis (Teoh, Welch, & Wong, 1998; DeFond & Jiambalvo, 1994; Jaggi & Lee, 2002; Van Tendeloo & Vanstraelen, 2005). Nestas pesquisas, prevalece o pressuposto de que a manipulação dos lucros ocorre através de *accruals*, levando ao desenvolvimento de modelos que buscam distinguir os *accruals* totais em não discricionários (esperados) e discricionários (inesperados), sendo estes últimos considerados como *proxy* para a gerenciamento de resultados.

Um problema fundamental de tal abordagem é que o gerenciamento de resultados não é mensurável diretamente. Desta forma, as atividades relacionadas a tal prática costumam ser de difícil distinção, dentro do universo de atividades normais dos negócios. Assim, a avaliação do desempenho real desses modelos pode ser problemática.

A capacidade dos modelos na extração da parte discricionária dos *accruals* foi questionada em diversos estudos (por exemplo, Dechow et al., 1995; Xie (2001); Dechow et al., 2003). Thomas e Zhang (2000), por exemplo, concluíram que a maioria desses modelos apresentam desempenho pior do que apenas a simples suposição de que os *accruals* discricionários equivalem a 5% dos ativos totais. Outras explicações para as limitações, incluem dados ruidosos e o uso de abordagens lineares em um processo de *accrual* que é, por natureza, não linear (Dechow, Sloan, & Sweeney, 1995; Jeter & Shivakumar, 1999; Kothari, Leone e Wasley, 2005).

Esta situação levanta uma questão crucial: as técnicas de *machine learnig* são um caminho viável na busca de soluções para os problemas encontrados em modelos tradicionais de detecção de gerenciamento de resultados? Estudos recentes destacam a eficácia de ferramentas de *machine learnig* na previsão de erros e irregularidades, na medição do conteúdo informacional, na análise de demonstrações financeiras e na melhoria dos procedimentos de auditoria (Perols, 2011; Perols et al., 2017; Bertomeu et al., 2020; Bao et al., 2020; Li, 2010; Barth et al., 2019; Binz et al., 2020; Gerakos et al., 2016; Sun, 2019). Este interesse crescente significa uma abordagem transformadora para enfrentar as complexidades da gestão de resultados e melhorar a qualidade dos relatórios financeiros.

Dechow et al. (2012) propuseram um procedimento para abordar os problemas associados às técnicas tradicionais, incorporando as informações dos pesquisadores sobre a reversão dos *accruals* discricionários. Esta abordagem pode ser adaptada para utilização em todos os modelos tradicionais de detecção de gerenciamento de resultados com base em *accruals*.

Porém, como destacado pelos autores supracitados, este procedimento requer que o pesquisador identifique os períodos em que se espera que os *accruals* sejam manipulados, assim como os períodos com expectativa de suas reversões. Neste ponto, o presente trabalho pretende testar se a utilização de algoritmos de *machine learning* para a determinação de tais períodos promove melhorias no poder de explicação em relação ao modelo original.

## 4.2. Referencial

### 4.2.1. Problemas do Teste Conjunto de Hipóteses

De forma geral, a qualidade dos lucros de uma determinada empresa depende, concomitantemente, de sua performance real (fator não observado diretamente) e da qualidade do sistema contábil, responsável por sua mensuração. Neste ponto, a literatura relacionada apresenta fraquezas relevantes, tanto em termos de quantidade de trabalhos que enfrentam a questão, quanto em termos de sucesso na tentativa de distinção destes efeitos nos resultados apresentados (Dechow, Ge, & Schrand, 2010).

Um princípio básico de um sistema de mensuração baseado em regime de competência é que os lucros contábeis suavizam as flutuações relacionadas aos fluxos de caixa, fornecendo aos resultados contábeis maior capacidade informativa sobre o desempenho. Embora os pronunciamentos que tratam dos conceitos contábeis não afirmem que a “suavização” é, necessariamente, uma propriedade desejável dos lucros, o objetivo dos normatizadores está pautado na busca de uma representação do real desempenho econômico/financeiro das empresas que melhore a previsibilidade dos fluxos de caixa futuros. A suavização, por conseguinte, seria o resultado de um sistema baseado em *accruals*, assumindo-se que estes melhoram a utilidade da decisão, e não o objetivo final do sistema (Dechow, Ge, & Schrand, 2010).

No entanto, conforme observado por DeFond (2010), desenvolver um modelo de qualidade dos *accruals* que separe o papel do sistema contábil e da real performance é um problema que nunca será resolvido por completo, visto que a performance real não é observável. Além disso, pode haver um ciclo de *feedback*: o sistema contábil pode influenciar o comportamento da administração que, por sua vez, altera o valor dos lucros “fundamentais” e, conseqüentemente, sua qualidade. Por exemplo, não exigir a contabilização de opções de ações pode resultar em maior uso de opções de ações do que ocorreria, o que poderia afetar o comportamento baseado na aversão ao risco, o que, por sua vez, afetará o processo de formação dos lucros, fundamentalmente (Ewert & Wagenhofer, 2011).

Os problemas advindos das falhas de identificação dos efeitos de cada um destes aspectos são evidentes em pesquisas que tratam de temas relacionados a persistência dos lucros, *earnings smoothing* e *accruals* anormais. *Earnings smoothing*, por exemplo, é representada tanto como uma *proxy* para gerenciamento de resultados, ou seja, indicativo de baixa qualidade dos lucros, quanto como uma parcela adicional de informação incorporada aos lucros pelos gerentes, representando, assim, uma qualidade informacional superior (Ewert, & Wagenhofer, 2012).

Com relação à persistência dos lucros, em seu trabalho seminal, Sloan (1996) interpreta o menor impacto da parcela representativa dos *accruals* na persistência dos lucros, em comparação à parcela referente aos fluxos de caixa, como sendo originária de problemas do sistema contábil, no que tange à mensuração, tanto pela incapacidade de refletir a real performance da empresa, quanto por problemas associados às possibilidades de discricionariedade, permitidas pelo sistema. Porém, Fairfield et al. (2003) desenvolvem uma outra explicação sobre o menor impacto dos *accruals* na persistência dos lucros. Esta estaria relacionada ao efeito causado pelo aumento da performance na persistência dos resultados. Mais precisamente, os autores se pautam na observação de que, na medida em que os setores expandem, se torna cada vez mais difícil manter os mesmos preços para os bens negociados, o que impacta negativamente nas margens de lucro, em suma, a menor persistência dos

resultados ocorre naturalmente pela existência de retornos marginais decrescentes, e não pela qualidade informacional dos *accruals*.

De forma geral, as evidências dos trabalhos que estudam as consequências da suavização dos lucros não fornecem uma conclusão clara. A variação cross-seccional desta variável pode ser resultado do próprio desempenho real da empresa, da maior ou menor capacidade representativa do sistema de mensuração contábil ou da heterogeneidade das escolhas contábeis por parte dos gestores. Ainda, tais escolhas podem ter o objetivo tanto de aumentar a utilidade das decisões quanto de distorcê-las. Assim, faz-se necessário a devida separação desses aspectos, pois cada elemento terá implicações diferentes para a utilidade da decisão (Dechow, Ge, & Schrand, 2010).

#### 4.2.2. Eficiência de Mercado vs Qualidade dos Lucros

O que se considera finanças “modernas” surgiu da matemática relacionada à probabilidade e estatística. O conceito fundamental desta nova escola diz que os preços não são previsíveis, mas suas flutuações podem ser descritas pelas leis matemáticas da probabilidade. Portanto, seu risco é mensurável e gerenciável (Mandelbrot & Hudson, 2010).

As pesquisas sobre preços de ações não começaram com o desenvolvimento de uma teoria da formação de tais preços, para que depois fosse então submetida a testes empíricos. A inspiração para o desenvolvimento de uma teoria veio, primeiramente, do acúmulo de evidências, a partir de meados da década de 1950 e início da década de 1960. Tais evidências levaram os pesquisadores a considerar que o comportamento das ações ordinárias e outros títulos se aproximava relativamente bem do que se considera um “passeio aleatório” (*random walk*). A partir de então, os economistas se sentiram compelidos a oferecer alguma racionalização. O que resultou foi uma teoria de mercados eficientes estabelecida em termos de passeios aleatórios, mas geralmente implicando em um modelo mais geral de “jogo justo” (*fair game*) (Fama, 1970).

Segundo Fama (1991), a hipótese de eficiência do mercado pode ser resumida na simples afirmação de que os preços dos títulos refletem totalmente todas as informações disponíveis. Uma pré-condição para essa versão forte da hipótese é que os custos de informação e negociação, são sempre nulos. Uma versão mais fraca e economicamente mais parcimoniosa da hipótese da eficiência diz que os preços refletem as informações até o ponto em que os benefícios marginais de agir com base nas informações (os retornos a serem obtidos) não excedem os custos marginais.

Segundo Mandelbrot e Hudson (2010), a teoria é elegante, mas falha. O que os autores consideram uma antiga ortodoxia financeira foi fundada em duas suposições críticas no modelo principal do matemático francês, Louis Bachelier: as mudanças nos preços são estatisticamente independentes e normalmente distribuídas. Os fatos, que muitos economistas agora reconhecem, mostram o contrário (Mandelbrot & Hudson, 2010).

Segundo Barber e Odean (2013), a maior parte da pesquisa com base na moderna teoria de finanças foi construída com a noção de que os seres humanos são agentes racionais que tentam maximizar a riqueza e minimizar os riscos. Esses agentes avaliam cuidadosamente o risco e o retorno de todas as opções de investimento possíveis para chegar a um portfólio de investimentos adequado às suas necessidades e nível de aversão ao risco. Um grande conjunto de pesquisas empíricas, segundo os autores, indica que os investidores individuais reais se comportam de maneira diferente dos investidores nesses modelos. Muitos investidores



individuais possuem carteiras pouco diversificadas, outros, aparentemente desinformados, negociam ativamente, especulativamente e em seu próprio desfavor. Como um grupo, investidores individuais tomam decisões sistemáticas (não aleatórias) de compra e venda.

Com relação aos ruídos que se observam no processo de formação de preços de ativos nos mercados de capitais, alguns estudos indicam que investidores individuais geralmente negligenciam informações contábeis relevantes para a determinação do valor do ativo (Lee (1992); Maines & Hand (1996); Hirshleifer et al. (2008); Taylor (2010); Ayers, Li & Yeung (2011)) e suas carteiras de títulos apresentam desempenho inferior porque buscam tendências que chamam sua atenção (Barber & Odean, 2013).

O trabalho de Blankespoor, Dehaan, Wertz e Zhu (2019), propôs investigar os atritos que impedem o uso de informações contábeis por investidores individuais e, em particular, seus custos de monitoramento e aquisição de informações contábeis divulgadas. Em sua abordagem, partiram da implementação, de forma gradativa, dos *Associated Press's* (AP), “artigos de jornal” gerados automaticamente (artigos gerados por algoritmos), distribuídos nacionalmente (nos EUA). Os autores exploraram tal recurso, pois todos os artigos apresentam os lucros atuais das empresas e os retornos finais das ações de maneira padronizada, permitindo examinar as opções de negociação de indivíduos quando as informações contábeis e as tendências “técnicas” estão imediatamente à mão. Os resultados indicaram que os indivíduos ignoram as informações sobre lucros, mesmo na ausência de custos de “percepção” (*awareness costs*) e de aquisição de informações (*aquisition costs*), indicando que algum outro atrito afeta suas negociações.

A heterogeneidade informacional dos investidores pode estar relacionada à características específicas de cada investidor, seja devido aos aspectos exógenos ou endógenos do processo de aquisição de informações. A heterogeneidade também pode estar relacionada às características das empresas, tanto no que diz respeito a aspectos (exógenos) do sistema de relatórios financeiros, que afetam sua capacidade de fornecer informações relevantes, ou devido às decisões (endógenas) relacionadas à produção de informações, o que inclui decisões relativas a gerenciar lucros ou fazer divulgações voluntárias (Dechow, Ge, & Schrand, 2010).

Com relação ao comportamento especulativo dos investidores, o estudo de Dimitropoulos e Asteriou (2010), por exemplo, teve como objetivo examinar a relevância dos lucros e valores contábeis nos preços das ações e testar o efeito da intensidade especulativa sobre a relevância da informação contábil entre 1995 e 2004. Os resultados indicaram que os valores contábeis não são relevantes quando são considerados isoladamente e, em contrapartida, o efeito da intensidade especulativa sobre os preços das ações é positivo e significativo. Consequentemente, os modelos clássicos de avaliação são mal especificados e podem produzir viés significativo se a intensidade especulativa não for levada em consideração.

Alguns trabalhos comparam as transações no mercado de capitais com os jogos de aposta, em geral e, mais especificamente com as loterias (Pavalko, 2001, Statman, 2002, Shiller, 2005). No mesmo sentido, Grinblatt e Keloharju (2009) argumentam que a sensação ou busca de emoção, entendido como um atributo psicológico estável, sugerido por Zuckerman (1994), fundamenta tanto a propensão a apostar quanto a propensão às transações nos mercados de capitais.

Sloan (1996) relata que uma estratégia de *trading* baseada no nível de *accruals* contido nos lucros reportados gera retornos anormais de 12% ao ano. Estudos subsequentes forneceram várias explicações para tal retorno, incluindo: entendimento incorreto dos

investidores sobre o real impacto dos *accruals* anormais (Xie, 2001); sobre os erros relacionados aos *accruals*, ou confiabilidade dos mesmos (Richardson et al., 2006; Hirshleifer, & Teoh, 2003); sobre o potencial de crescimento refletido nos *accruals* (Desai et al., 2004; Fairfield et al., 2003; Zhang, 2007); e pela mensuração incorreta dos retornos esperados ou outros problemas de pesquisa dos trabalhos que tratam do assunto (Kraft et al., 2006; Khan, 2008).

Muitas pesquisas empíricas, dentre as publicadas a partir dos anos 1960, geralmente parecem ser testes de hipóteses com base em bancos de dados convenientemente disponíveis, em vez de testes de hipóteses projetados para fornecer informações sobre a resposta do mercado de capitais a mensurações e divulgações contábeis, obrigatórias ou voluntárias (Dyckman & Zeff, 2015).

#### 4.2.3. Questões Econométricas

Em estudos empíricos de gerenciamento de resultados, uma questão central é a estimativa do componente gerenciado (*accruals* discricionários), sendo esta observada apenas externamente, ou seja, apenas a soma dos números contábeis gerenciados e não gerenciados (não discricionários). Questões metodológicas importantes surgem em parte porque as variáveis mais úteis na previsão dos componentes não gerenciados são os próprios números contábeis que provavelmente serão afetados pelo próprio processo de gerenciamento (Kang, & Sivaramakrishnan, 1995).

Um ponto importante relacionado a esses modelos é que as medidas de *accruals* anormais obtidas a partir dos modelos tendem a ser positivamente correlacionadas com o nível de *accruals*. Em outras palavras, uma empresa com *accruals* extremos também tem *accruals* anormais extremos. Esta observação é importante para interpretar os resultados da literatura. A correlação levanta preocupações sobre se os *accruals* anormais refletem distorções contábeis ou se, em vez disso, são o resultado de modelos de *accruals* mal especificados e incluem um componente que mede o desempenho fundamental. Erros de classificação incorreta podem incluir erros do Tipo I, que classificam os *accruals* como anormais quando são uma representação do desempenho fundamental (ou seja, um falso positivo) e erros do Tipo II, que classificam os *accruals* como normais quando não são (Dechow, Ge, & Schrand, 2010).

Algumas das razões para os resultados empíricos fracos e inconsistentes, segundo Sunder (1997), são: uso de *proxies* não confiáveis para representar as parcelas gerenciadas e não gerenciadas dos lucros; foco da maioria dos estudos empíricos em um aspecto do gerenciamento de resultados por vez; interpretação restrita do gerenciamento de resultados; e incentivos dos gerentes para esconder os rastros de suas ações. Arya, Glover e Sunder (1998) sugerem outras duas razões: os proprietários podem ter incentivos para tornar mais fácil para os gestores ocultar informações; e duas ou mais condições independentes que induzem o gerenciamento de resultados podem existir simultaneamente, fazendo com que estudos que se concentram em uma única condição gerem ruído resultados.

Fields et al. (2001), analisando os problemas de especificação dos modelos de *accruals*, argumentam que, mesmo os trabalhos que consideram múltiplas motivações, geralmente os tratam de forma independente. Porém, na prática, os administradores enfrentam uma variedade de conflitos em cada decisão, sugerindo que suas ações não consistentes, em média. Portanto, a dificuldade na especificação de uma metodologia adequada está na

complexidade das atividades envolvidas, ou seja, advém do impacto simultâneo das múltiplas escolhas e objetivos, além de complicações de identificação das relações entre elas e, finalmente, dos problemas de mensuração das *proxies* escolhidas. De forma semelhante, McNichols (2000) reforçam a dimensão do desafio enfrentado na busca da identificação e controle de potenciais variáveis omitidas correlacionadas, visto a base teórica limitada no que diz respeito ao comportamento dos *accruals* na ausência de discricionariedade.

Outro ponto de fundamental importância se refere ao comportamento não linear dos lucros devido a diversos fatores. Kothari et al. (2005) destaca que desempenhos extremos tendem a reverter à média, ao passo que um desempenho médio é bastante persistente, o que implica uma relação não linear entre o desempenho atual e futuro em toda parcela cross-sectional. Os autores ressaltam outra fonte de comportamento não linear como resultado da tendência dos gestores de proceder a um “*big bath*”, em momentos economicamente ruins. Outras razões incluem conservadorismo contábil e incentivos para gerenciamento de resultados (Watts, & Zimmerman, 1986; Basu, 1997; Watts, 2003).

### 4.3. Metodologia

Dechow et al. (2012) enfatizam que as técnicas existentes para medir o gerenciamento de resultados possuem baixo poder para níveis razoáveis de gerenciamento de resultados devido à pouca capacidade dos modelos de isolar os *accruals* discricionários. Além disso, os testes com essas técnicas são incorretamente especificados devido a variáveis omitidas correlacionadas em amostras com desempenho financeiro extremo, situação não incomum em testes de gerenciamento de resultados.

Um ponto de suma importância para a discussão sobre as práticas de gerenciamento de resultados é descrito por Scott (2014) como uma lei fundamental (*iron law*) desse processo, com base em regime de competência, qual seja: a necessária reversão dos *accruals*. Assim, sempre que ocorre um gerenciamento positivo nos lucros, em um valor maior do que pode ser sustentado, a reversão desses *accruals* em períodos subsequentes forçará os lucros futuros para baixo.

Em contrapartida, *accruals* não discricionários estão vinculados às operações subjacentes aos negócios da empresa, como destacado por McNichols (2000). Tais *accruals* tendem a se originar em períodos de crescimento das operações, ou quando ocorrem mudanças estratégicas em decisões operacionais e/ou de investimento. Com base na perspectiva de que as empresas operam em um contexto de continuidade, suas características operacionais tendem a persistir, assim como os *accruals* não discricionários relacionados. De forma geral, a reversão de *accruals* não discricionários tende a ser compensada por outros de mesma natureza, exibindo, de forma agregada, persistência ao longo do tempo Dechow et al. (2012).

Com base nesta “lei”, Dechow et al. (2012) propuseram um procedimento para abordar os problemas associados às técnicas tradicionais, incorporando as informações dos pesquisadores sobre a reversão dos *accruals* discricionários. Esta abordagem pode ser adaptada para utilização em todos os modelos tradicionais de detecção de gerenciamento de resultados com base em *accruals*.

Porém, como destacado pelos autores supracitados, este procedimento requer que o pesquisador identifique os períodos em que se espera que os *accruals* sejam manipulados, assim como os períodos com expectativa de suas reversões. Neste ponto, o presente trabalho pretende testar se a utilização de algoritmos de *machine learning* para a determinação de tais períodos promove melhorias no poder de explicação em relação ao modelo original.

Para tanto, esta pesquisa possui três etapas principais:

1. treinamento e seleção do algoritmo de *machine learning* com o melhor desempenho;
2. comparação entre os resultados das regressões de modelos clássicos de detecção de gerenciamento de resultados com base em *accruals* e os resultados dos mesmos modelos modificados pela inclusão de variáveis *dummy* geradas pelo algoritmo selecionado na etapa 1; e
3. comparação dos resultados de regressões utilizando os resíduos encontrados na etapa 2 contra as *dummies* geradas por simulações.

Todas as etapas se baseiam em simulações aleatórias de induções e reversões de gerenciamento de resultados, seguindo a estrutura proposta por Dechow et al. (2012).

### 4.3.1. Amostra

A amostra inicial desta pesquisa conta com 282 empresas não financeiras com ações negociadas na B3 entre os anos de 2010 (quarto trimestre) e 2022 (quarto trimestre). Os dados utilizados foram retirados das Demonstrações Financeiras em frequência trimestral, representando um total de 7.866 observações firma-trimestre. Desta amostra inicial, subdividiu-se em duas partes: uma para treinamento dos algoritmos de *machine learning* e outra para os testes realizados com regressões. A primeira conta com dados contidos no período entre 2010 (quarto trimestre) e 2011 (quarto trimestre), representando um total de 657 observações firma-trimestre. A segunda engloba o restante, com um total de 7.209 observações firma-trimestre.

## 4.4. Treinamento dos Algoritmos de *Machine Learning*

Diware, Borhade e Ringe (2016) argumentam que nenhum algoritmo de aprendizagem pode superar consistentemente outros algoritmos em todos os conjuntos de dados. Portanto, as decisões sobre o tipo de algoritmo a ser utilizado devem ser tomadas com base no tipo de problema de classificação e na precisão do algoritmo aplicado que melhor se adapta. O presente estudo utiliza 14 algoritmos de *machine learning*, conforme Quadro 1.

**Quadro 1:** Algoritmos de *Machine Learning* utilizados.

| Algoritmo                              | Biblioteca (Python)  |
|--|--|
| <i>Ada Boost Classifier</i>            | <code>sklearn.ensemble._weight_boosting.AdaBoostClas...</code> |
| <i>Decision Tree Classifier</i>        | <code>sklearn.tree._classes.DecisionTreeClassifier</code>      |
| <i>Dummy Classifier</i>                | <code>sklearn.dummy.DummyClassifier</code>                     |
| <i>Extra Trees Classifier</i>          | <code>sklearn.ensemble._forest.ExtraTreesClassifier</code>     |
| <i>Gradient Boosting Classifier</i>    | <code>sklearn.ensemble._gb.GradientBoostingClassifier</code>   |
| <i>K Neighbors Classifier</i>          | <code>sklearn.neighbors._classification.KNeighborsCl...</code> |
| <i>Light Gradient Boosting Machine</i> | <code>lightgbm.sklearn.LGBMClassifier</code>                   |
| <i>Linear Discriminant Analysis</i>    | <code>sklearn.discriminant_analysis.LinearDiscrimina...</code> |
| <i>Logistic Regression</i>             | <code>sklearn.linear_model._logistic.LogisticRegression</code> |
| <i>Naive Bayes</i>                     | <code>sklearn.naive_bayes.GaussianNB</code>                    |
| <i>Quadratic Discriminant Analysis</i> | <code>sklearn.discriminant_analysis.QuadraticDiscrim...</code> |
| <i>Random Forest Classifier</i>        | <code>sklearn.ensemble._forest.RandomForestClassifier</code>   |
| <i>Ridge Classifier</i>                | <code>sklearn.linear_model._ridge.RidgeClassifier</code>       |
| <i>SVM - Linear Kernel</i>             | <code>sklearn.linear_model._stochastic_gradient.SGDC...</code> |

Fonte: Elaborado pelos autores.

Para o treinamento supervisionado dos algoritmos, é necessário que o banco de dados contenha informações sobre a ocorrência do fenômeno que é objeto do treinamento, ou seja, as observações firma-trimestre para as quais se incluiu valores representativos de gerenciamentos contábeis, assim como suas reversões.

Visto que o objetivo principal deste trabalho é testar se a utilização de ferramentas de *machine learning* na determinação dos períodos de início de manipulação dos *accruals*, assim como dos períodos de reversão, melhora o poder explicação do modelo proposto por Dechow et al. (2012), o treinamento dos algoritmos ocorre visando manter a mesma estrutura metodológica utilizada pelos autores. Algumas diferenças, porém, são descritas a seguir.

Dechow et al. (2012) partem da hipótese de que os períodos de início e reversão das parcelas de resultados gerenciados são mutuamente excludentes. O presente trabalho, porém, relaxa esta hipótese, ou seja, considera que podem ocorrer sobreposições dos períodos, visto

que esta prática possui um dinamismo natural, ou seja: valores gerenciados em períodos anteriores podem estar sendo revertidos no período atual e, conjuntamente, pode ocorrer um novo “início” no processo, com mais uma inclusão de valores gerenciados com base nos resultados atuais da entidade. Desta forma, para o treinamento e teste dos algoritmos de *machine learning*, foram definidas 7 situações possíveis em termos de gerenciamento. Tais cenários representam as classificações (*Labels*) de referência para o treinamento, descritas no Quadro 2.

**Quadro 2:** Labels para treinamento dos algoritmos de *machine learning*.

| <i>Labels</i> | Definições   |
|---------------|--|
| <b>0</b>      | Ausência de gerenciamento  |
| <b>1</b>      | Início do gerenciamento  |
| <b>2</b>      | Primeira reversão subsequente (50%)  |
| <b>3</b>      | Segunda reversão subsequente (50%)   |
| <b>4</b>      | Início do gerenciamento & Primeira reversão subsequente (50%)                                      |
| <b>5</b>      | Início do gerenciamento & Segunda reversão subsequente (50%)                                       |
| <b>6</b>      | Início do gerenciamento & Primeira reversão subsequente (50%) & Segunda reversão subsequente (50%) |

Fonte: Elaborado pelos autores.

Outro aspecto de diferenciação no treinamento dos algoritmos está associado à quantidade de eventos de interesse (ocorrência do fenômeno que é objeto do treinamento) que, no caso do presente estudo, são as observações firma-trimestre para as quais se incluiu valores representativos de gerenciamentos contábeis, assim como suas reversões. Utilizou-se o máximo de instâncias possíveis para o treinamento, representando um total de 40% das observações da amostra de treinamento. Este percentual máximo de ocorrências simuladas se deve às características da amostra em conjunto a uma escolha metodológica: utilizou-se, como base para as inclusões de gerenciamento, apenas as variações positivas dos Ativos Totais.

A importância de se utilizar um número relativamente grande de eventos de interesse (instâncias positivas) ao treinar um algoritmo de *machine learning* se deve a vários motivos importantes, tais como:

1. **Maior capacidade de generalização do modelo:** com um grande número de instâncias positivas, o algoritmo de aprendizado de máquina tem mais dados para aprender. Isso geralmente leva a uma melhor generalização, o que significa que o modelo é melhor em fazer previsões precisas sobre dados novos e não vistos. Um modelo treinado em um pequeno número de instâncias positivas pode memorizar os dados de treinamento em vez de aprender padrões significativos, o que pode resultar em baixo desempenho em novos dados;
2. **Menor risco de *overfitting*:** o *overfitting* ocorre quando um modelo “aprende” com o ruído dos dados de treinamento em vez dos padrões subjacentes. Com um número maior de instâncias positivas, o risco de *overfitting* é reduzido. Um modelo treinado em um pequeno número de ocorrências tem maior probabilidade de se “ajustar demais”, pois pode capturar ruídos ou valores discrepantes como se fossem características essenciais da classe positiva;
3. **Maior estabilidade nas métricas de avaliação:** métricas de avaliação podem ser altamente instáveis quando o número de instâncias positivas é pequeno. Pequenas mudanças nas previsões podem levar a flutuações significativas nessas métricas. Com um número maior de instâncias positivas, as métricas de avaliação dos modelos tendem a ser mais estáveis e confiáveis;
4. **Redução do Viés:** um número relativamente baixo de instâncias positivas pode introduzir viés no modelo. O modelo pode subavaliar a importância da classe, levando

a previsões tendenciosas. Um número maior de ocorrências ajuda a reduzir esse viés, permitindo que o modelo faça previsões mais equilibradas; e

5. **Maior robustez ao desequilíbrio entre classes:** em muitos problemas reais, o desequilíbrio entre classes é comum, ou seja, o número de instâncias negativas (não eventos) supera significativamente o número de instâncias positivas (eventos). Um número maior de instâncias positivas ajuda o modelo a lidar com esse desequilíbrio de classe de forma mais eficaz, melhorando sua capacidade de identificar eventos raros.

Portanto, ter um número relativamente grande de eventos de interesse ao treinar um algoritmo de *machine learning* é essencial para o desempenho, generalização e confiabilidade do modelo, ajudando a mitigar problemas como *overfitting*, instabilidade das métricas de avaliação e viés, ao mesmo tempo que melhora a capacidade do modelo de identificar eventos raros.

Para o treinamento dos algoritmos, parte-se da amostra base para o treinamento (quarto trimestre de 2010 ao quarto trimestre de 2011) e calcula-se a *proxy* de *accruals* totais, conforme Equação (1):

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1} \quad (1)$$

Onde:

|                    |   |
|--------------------|---|
| $\Delta CA_{it}$   | = variação no Ativo Circulante da empresa $i$ , no período $t$ ;          |
| $\Delta CL_{it}$   | = variação no Passivo Circulante da empresa $i$ , no período $t$ ;        |
| $\Delta Cash_{it}$ | = variação no Caixa da empresa $i$ , no período $t$ ;                     |
| $\Delta STD_{it}$  | = variação nas dívidas de curto prazo da empresa $i$ , no período $t$ ; e |
| $Assets_{it-1}$    | = Ativo Total da empresa $i$ , no período anterior a $t$ .                |

A partir de então, seguem-se as seguintes etapas:

1. Selecionam-se 40% das observações da amostra de *proxy* de *accruals* totais aleatoriamente. A estas são incluídas parcelas de gerenciamento gerados artificialmente (*accruals* discricionários) equivalentes a 1% da variação dos Ativos Totais;
2. Caso haja observações da mesma firma nos dois períodos imediatamente posteriores aos selecionados na etapa anterior, efetuam-se reversões do gerenciamento induzido na etapa 1 (50% de reversão em cada período subsequente);
3. Repetem-se as etapas 1 e 2 50 vezes para gerar a amostra final a ser utilizada no treinamento;
4. A partir da amostra final, procede-se ao treinamento e validação (*ten-fold cross-validation*) dos 14 algoritmos, conforme descritos no Quadro 1.

A seleção do algoritmo de *machine learning* a ser utilizado nos testes com regressões se baseia na análise dos resultados das seguintes métricas: **Accuracy**, **AUC** (*Area Under the Curve*), **Recall**, **Precision**, **F1** (*F1 score*), **Kappa** (*Cohen's Kappa*), e **MCC** (*Matthews Correlation Coefficient*).

#### 4.5. Modelos Utilizados nos Testes com Regressões

Após o treinamento, validação e seleção do algoritmo de *machine learning*, parte-se para a segunda etapa geral do trabalho: comparação entre os resultados das regressões de

modelos clássicos de detecção de gerenciamento de resultados com base em *accruals* e os resultados dos mesmos modelos modificados pela inclusão de variáveis *dummy* geradas pelo algoritmo selecionado.

Para tanto, visando maior comparabilidade com o trabalho de Dechow et al. (2012), utilizam-se quatro modelos testados naquela pesquisa: Dechow e Dichev (2002), Jones (1991), Dechow et al. (1995) (Jones Modificado) e McNichols (2002). A partir destes, outros quatro modelos são gerados, modificando-os com a introdução de variáveis *dummy* geradas pelo algoritmo selecionado (conforme seção anterior).

Os 8 modelos são chamados Modelos Base nesta pesquisa pois são a base a partir da qual procede-se à terceira etapa geral: comparação dos resultados de regressões utilizando os resíduos encontrados na segunda etapa geral (*proxies* de gerenciamento de resultados) contra as *dummies* representativas das inclusões e reversões de gerenciamento de resultados artificiais. Para a comparação dos resultados, utiliza-se a estrutura do Modelo Geral (Modelo (2)). As descrições de todos os modelos utilizados nos testes com regressões são apresentadas nas próximas duas subseções.

#### 4.5.1. Estrutura do Modelo Geral

O **Modelo Geral** baseia-se na estrutura introduzida por McNichols e Wilson (1988) e ampliada por Dechow, Sloan e Sweeney (1995) e Dechow et al. (2012):

$$MG_m = DAP_{mit} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it} \quad (2)$$

Onde:

$MG_m$  = Modelo Geral, sendo o subscrito  $m$  referente a cada Modelo Base ( $MB_m$ ), dos quais derivam-se as variáveis independentes ( $DAP_{mit}$ );

$DAP_{mit}$  = *proxy* de *accruals* discricionários do modelo em estudo, sendo o subscrito  $m$  referente a cada modelo utilizado para os testes de poder e especificidade;

$P_{it}$  = variável *dummy* que assume valor 1 para observações com gerenciamento induzido e 0, caso contrário;

$PR1_{it}$  = variável *dummy* que assume valor 1 para observações com reversão do gerenciamento induzido no ano subsequente à indução e 0, caso contrário;

$PR2_{it}$  = variável *dummy* que assume valor 1 para observações com reversão do gerenciamento induzido no segundo ano subsequente à indução e 0, caso contrário;

A variável independente do **Modelo Geral** representa as *proxies* de *accruals* discricionários ( $DAP_{mit}$ ) que, por sua vez, são determinados a partir de oito **Modelos Base** (descritos na próxima seção).

#### 4.5.2. Modelos Base

Os Modelos Base utilizados neste trabalho são modelos de detecção de gerenciamento de resultados por *accruals* que envolvem a determinação de dois aspectos: *proxy* representativa dos *accruals* totais e determinantes da parcela não discricionária dos *accruals* totais. Desta forma, seguindo Dechow et al. (2012), temos:

$$Wc\_Acc_{it} = \alpha + \sum_k f_k X_{kit} + \delta_{mit} \quad (3)$$

Onde:



$Wc\_Acc_{it}$  = proxy dos *accruals* totais da empresa  $i$ , no período  $t$ , calculados conforme Equação (1);  
 $X_{kit}$  = variáveis de controle da parcela não discricionária dos *accruals* para cada modelo.  
 $\delta_{mit}$  = termo de erro da regressão para cada Modelo Base  $m$ ;

Porém, visto que o objetivo principal desta pesquisa é testar se a utilização de ferramentas de *machine learning* na determinação dos períodos de início de manipulação dos *accruals*, assim como dos períodos de reversão, melhora o poder de explicação do modelo proposto por Dechow et al. (2012), modifica-se a estrutura do Modelo 3 da seguinte forma:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \sum_k f_k X_{kit} + \delta_{mit} \quad (4)$$

Onde:

$P\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão de gerenciamento induzido e 0, caso contrário;  
 $PR1\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão de reversão de 50% do gerenciamento induzido no ano subsequente e 0, caso contrário;  
 $PR2\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão de reversão de 50% do gerenciamento induzido no segundo ano subsequente à indução e 0, caso contrário.

Portanto, após a escolha e treinamento (conforme descrito na Seção anterior) do melhor algoritmo de *machine learning*, tem-se os resultados apurados para a amostra de teste. Os *outputs* do algoritmo representam os *Labels* (classificações), conforme descritas no Quadro 2. Os valores das variáveis *dummy* geradas com base no algoritmo, portanto, são definidas conforme Quadro 3.

**Quadro 3:** *Labels* e respectivos valores para *dummies*.

| <i>Labels</i> | $P\_ML_{it}$ | $PR1\_ML_{it}$ | $PR2\_ML_{it}$ |
|---------------|--------------|----------------|----------------|
| <b>0</b>      | 0            | 0              | 0              |
| <b>1</b>      | 1            | 0              | 0              |
| <b>2</b>      | 0            | 1              | 0              |
| <b>3</b>      | 0            | 0              | 1              |
| <b>4</b>      | 1            | 1              | 0              |
| <b>5</b>      | 1            | 0              | 1              |
| <b>6</b>      | 1            | 1              | 1              |

**Fonte:** Elaborado pelos autores.

As variáveis representativas da parcela não discricionária ( $X_{kit}$ ) terão por base quatro modelos tradicionais de detecção de gerenciamento de resultados: Dechow e Dichev (2002), Jones (1991), Dechow et al. (1995) (Jones Modificado) e McNichols (2002). Desta forma, temos oito Modelos Base: quatro modelos de detecção de gerenciamento de resultados em sua forma original (estrutura do Modelo 3); e quatro modelos gerados a partir da modificação dos modelos originais (conforme estrutura do Modelo 4).

A seguir, são definidas as variáveis representativas da parcela não discricionária ( $X_{kit}$ ) para cada modelo utilizado em sua forma original.

### **Modelo Base 1 – MB<sub>1</sub>:**

Modelo proposto por Dechow e Dichev (2002):

$$Wc\_Acc_{it} = \alpha + \gamma_1 CFO_{it-1} + \gamma_2 CFO_{it} + \gamma_3 CFO_{it+1} + \delta_{1it} \quad (5)$$

Onde:

$X_{1it} = CFO_{it-1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t-1$ ;

$X_{2it} = CFO_{it}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t$ ;  
 $X_{3it} = CFO_{it+1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t+1$ ;

### **Modelo Base 2 – MB<sub>2</sub>:**

Modelo proposto por Jones (1991):

$$Wc\_Acc_{it} = \alpha + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \delta_{2it} \quad (6)$$

Onde:

$X_{1it} = \Delta Rev_{it}$  = Variação das Receitas da empresa  $i$ , no período  $t$ , dividida pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ );  
 $X_{2it} = PPE_{it}$  = Ativo Imobilizado da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ ).

### **Modelo Base 3 – MB<sub>3</sub>:**

Modificação do modelo Jones (1991) por Dechow et al. (1995):

$$Wc\_Acc_{it} = \alpha + \gamma_1 PPE_{it} + \gamma_2 (\Delta Rev_{it} - \Delta Rec_{it}) + \delta_{3it} \quad (7)$$

Cuja diferença, em relação ao modelo Jones original, é representada pela variável  $X_{2it}$ :

$X_{1it} = \Delta Rev_{it}$  = Variação das Receitas da empresa  $i$ , no período  $t$ , dividida pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ );  
 $X_{2it} = \Delta Rec_{it}$  = variação nos recebíveis da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ );  
 $X_{3it} = PPE_{it}$  = Ativo Imobilizado da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ ).

### **Modelo Base 4 – MB<sub>4</sub>:**

McNichols (2002):

$$Wc\_Acc_{it} = \alpha + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \gamma_3 CFO_{it-1} + \gamma_4 CFO_{it} + \gamma_5 CFO_{it+1} + \delta_{4it} \quad (8)$$

Onde:

$X_{1it} = \Delta Rev_{it}$  = Variação das Receitas da empresa  $i$ , no período  $t$ , dividida pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ );  
 $X_{2it} = PPE_{it}$  = Ativo Imobilizado da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ );  
 $X_{3it} = CFO_{it-1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t-1$ ;  
 $X_{4it} = CFO_{it}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t$ ;  
 $X_{5it} = CFO_{it+1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t+1$ ;

Como salientado anteriormente, os outros quatro Modelos Base representam variações nos modelos **MB<sub>1</sub>**, **MB<sub>2</sub>**, **MB<sub>3</sub>** e **MB<sub>4</sub>**, apenas com a diferença relativa às variáveis *dummy* ( $P\_ML_{it}$ ,  $PR1\_ML_{it}$  e  $PR2\_ML_{it}$ ) geradas pelo algoritmo *de machine learning* de melhor performance na etapa de treinamento, da seguinte forma:

**MB<sub>5</sub>**: Modelo Dechow e Dichev (2002) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 CFO_{it-1} + \gamma_2 CFO_{it} + \gamma_3 CFO_{it+1} + \delta_{5it}; \quad (9)$$

**MB<sub>6</sub>**: Modelo Jones (1991) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \delta_{6it}; \quad (10)$$

**MB<sub>7</sub>**: Modelo Dechow et al. (1995) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 PPE_{it} + \gamma_2 (\Delta Rev_{it} - \Delta Rec_{it}) + \delta_{7it}; \quad (11)$$

**MB<sub>8</sub>**: Modelo McNichols (2002) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \gamma_3 CFO_{it-1} + \gamma_4 CFO_{it} + \gamma_5 CFO_{it+1} + \delta_{8it}; \quad (12)$$

Desta forma, temos as especificações dos 8 Modelos Gerais a partir dos Modelos Base:

**MG<sub>1</sub>**:

$$DAP_{1it} = \delta_{1it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it} \quad (13)$$

**MG<sub>2</sub>**:

$$DAP_{2it} = \delta_{2it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it} \quad (14)$$

**MG<sub>3</sub>**:

$$DAP_{3it} = \delta_{3it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it} \quad (15)$$

**MG<sub>4</sub>**:

$$DAP_{4it} = \delta_{4it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it} \quad (16)$$

**MG<sub>5</sub>**:

$$DAP_{5it} = \delta_{5it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it} \quad (17)$$

**MG<sub>6</sub>**:

$$DAP_{6it} = \delta_{6it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it} \quad (18)$$

**MG<sub>7</sub>**:

$$DAP_{7it} = \delta_{7it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it} \quad (19)$$

**MG<sub>8</sub>**:

$$DAP_{8it} = \delta_{8it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it} \quad (20)$$

#### 4.6. Etapas para Regressões Utilizando Simulações

Para todas as regressões utilizando os 16 modelos especificados na subseção anterior (modelos 5 a 20), são gerados dados com simulações de gerenciamento de resultados artificiais com base nas seguintes etapas:

1. Partindo-se da amostra base para as regressões (observações contidas entre o primeiro trimestre de 2012 e o quarto trimestre de 2022) seleciona-se uma parcela de observações aleatoriamente. A estas são incluídos valores representativos de

gerenciamento, gerados artificialmente (*accruals* discricionários) equivalentes a 1% da variação dos Ativos Totais do início do período;

2. A partir da amostra da etapa 1, selecionam-se os dois períodos subsequentes à inclusão artificial do gerenciamento (da mesma empresa), para os quais serão definidas as reversões do gerenciamento artificial (50% em cada período subsequente);
3. Repetem-se 1.000 vezes as etapas 1 e 2.

As parcelas das observações para as quais são incluídas parcelas de gerenciamentos artificiais são baseadas em pesquisas anteriores e representam dois cenários: amostras com baixo índice de ocorrência de gerenciamento de resultados (0,1% de ocorrência); e contextos de alta ocorrência de gerenciamento (20%).

O primeiro cenário (baixo índice de ocorrência do fenômeno) tem por objetivo simular o contexto no qual a pesquisa de Dechow et al. (2012) se baseou: simulações de gerenciamento artificiais para 100 observações firma-trimestre de um total de 209.530. Visto que o objetivo central deste trabalho compreende a avaliação do potencial apresentado pela utilização de algoritmos de *machine learning* em promover melhorias no poder explicativo dos modelos de detecção com base no método proposto pelos autores supracitados, o primeiro cenário visa maior comparabilidade com os resultados apurados naquela pesquisa.

O segundo cenário busca avaliar se os resultados apurados no primeiro contexto se mantêm em um ambiente de grande incidência de gerenciamento. O percentual definido para este cenário (20%) se baseia no trabalho de Dichev et al. (2013). Os autores realizaram uma pesquisa com 169 CFOs de empresas de capital aberto e realizaram entrevistas com 12 CFOs e dois normatizadores. Um dos *insights* levantados pelo trabalho aponta que, segundo percepções gerais dos CFOs, cerca de 20% das empresas gerenciam seus lucros de forma sistemática (qualquer que seja período sob análise).

## 4.7. Resultados

### 4.7.1. Estatísticas Descritivas

**Tabela 6:** Estatísticas descritivas das variáveis dependentes dos modelos testados na pesquisa.

| Estat.           | <i>PPE</i> | $\Delta Rev$ | $\Delta Rec$ | <i>CFO</i> |
|------------------|------------|--------------|--------------|------------|
| <b>N. Obs.</b>   | 7209       | 7209         | 7209         | 7209       |
| <b>Média</b>     | 0.2309     | 0.0109       | 0.0013       | 0.0133     |
| <b>Desvio P.</b> | 0.2069     | 0.1155       | 0.0342       | 0.0890     |
| <b>Mínimo</b>    | 0.0006     | -0.4316      | -0.1141      | -0.3430    |
| <b>25%</b>       | 0.0408     | -0.0115      | -0.0087      | -0.0244    |
| <b>50%</b>       | 0.1960     | 0.0036       | 0.0003       | 0.0182     |
| <b>75%</b>       | 0.3434     | 0.0238       | 0.0096       | 0.0623     |
| <b>Máximo</b>    | 0.9094     | 1.2846       | 0.2929       | 0.2658     |

**Obs.:** estatísticas descritivas das variáveis dependentes dos modelos testados na pesquisa, calculadas da seguinte forma:

$PPE_{it}$  = Ativo Imobilizado da empresa *i*, no período *t*, dividido

pelos Ativos Totais da empresa *i* no período anterior (*t-1*).

$\Delta Rev_{it}$  = Variação das Receitas da empresa *i*, no período *t*, dividida pelos Ativos Totais da empresa *i* no período anterior (*t-1*);

$\Delta Rec_{it}$  = variação nos recebíveis da empresa *i*, no período *t*, dividido pelos Ativos Totais da empresa *i* no período anterior (*t-1*).

$CFO_{it}$  = Fluxo de Caixa Operacional da empresa *i* no período *t*.

**Fonte:** Dados da pesquisa.

**Tabela 7:** Estatísticas descritivas da variável independente dos modelos testados na pesquisa.

**Painel A: Estatísticas da variável independente utilizada para treinamento.**

|             | N. Obs. | Média  | Desvio P. | Mínimo  | 25%     | 50%    | 75%    | Máximo |
|-------------|---------|--------|-----------|---------|---------|--------|--------|--------|
| $Wc\_Acc_t$ | 657     | 0.0192 | 0.1205    | -0.2130 | -0.0243 | 0.0025 | 0.0306 | 0.3388 |

**Painel B: Estatísticas da variável independente utilizada nos modelos para testes.**

|             | N. Obs. | Média  | Desvio P. | Mínimo  | 25%     | 50%     | 75%    | Máximo |
|-------------|---------|--------|-----------|---------|---------|---------|--------|--------|
| $Wc\_Acc_t$ | 7209    | 0.0009 | 0.0560    | -0.2130 | -0.0196 | -0.0004 | 0.0187 | 0.3388 |

**Obs.:** estatísticas descritivas dos *accruals* de capital de giro ( $Wc\_Acc$ ), calculado da seguinte forma:

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}$$

Onde:

$\Delta CA_{it}$  = variação no Ativo Circulante da empresa *i*, no período *t*;

$\Delta CL_{it}$  = variação no Passivo Circulante da empresa *i*, no período *t*;

$\Delta Cash_{it}$  = variação no Caixa da empresa *i*, no período *t*;

$\Delta STD_{it}$  = variação nas dívidas de curto prazo da empresa *i*, no período *t*; e

$Assets_{it-1}$  = Ativo Total da empresa *i*, no período anterior a *t*.

**Painel A** apresenta descritivas dos *accruals* de capital de giro ( $Wc\_Acc$ ) no período selecionado como base para o treinamento dos algoritmos de *machine learning*.

**Painel B** apresenta descritivas dos *accruals* de capital de giro ( $Wc\_Acc$ ) no período selecionado como base para os testes utilizando regressões.

**Fonte:** Dados da pesquisa.

## 4.8. Resultados do Treinamento dos Algoritmos de *Machine Learning*

### 4.8.1. Resultados Gerais do Treinamento

A Tabela 8 apresenta os resultados do treinamento dos algoritmos de *machine learning*. A tabela apresenta os algoritmos em ordem decrescente de acurácia (*Accuracy*). Dos quatorze algoritmos, três tiveram a melhor performance em todas as métricas utilizadas para a comparação: *Decision Tree Classifier*, *Random Forest Classifier* e *Extra Trees Classifier*. Visto que os resultados apurados foram idênticos para os três, selecionou-se um destes (*Decision Tree Classifier*) para os testes com regressões e, portanto, as análises dos resultados das métricas são voltadas a este.

**Tabela 8:** Resultados do treinamento dos algoritmos de *machine learning*.

| Modelo                                 | <i>Accuracy</i> | <i>AUC</i> | <i>Recall</i> | <i>Prec.</i> | <i>F1</i> | <i>Kappa</i> | <i>MCC</i> |
|--|-----------------|------------|---------------|--------------|-----------|--------------|------------|
| <i>Decision Tree Classifier</i>        | 0.8397          | 0.965      | 0.8397        | 0.8583       | 0.843     | 0.7924       | 0.7952     |
| <i>Random Forest Classifier</i>        | 0.8397          | 0.965      | 0.8397        | 0.8583       | 0.843     | 0.7924       | 0.7952     |
| <i>Extra Trees Classifier</i>          | 0.8397          | 0.965      | 0.8397        | 0.8583       | 0.843     | 0.7924       | 0.7952     |
| <i>K Neighbors Classifier</i>          | 0.8075          | 0.9328     | 0.8075        | 0.8161       | 0.81      | 0.7486       | 0.7494     |
| <i>Gradient Boosting Classifier</i>    | 0.5389          | 0.8387     | 0.5389        | 0.6385       | 0.4756    | 0.2651       | 0.3446     |
| <i>Light Gradient Boosting Machine</i> | 0.4793          | 0.789      | 0.4793        | 0.4299       | 0.4165    | 0.2172       | 0.2382     |
| <i>Logistic Regression</i>             | 0.428           | 0.485      | 0.428         | 0.1831       | 0.2565    | 0            | 0          |
| <i>Ridge Classifier</i>                | 0.428           | 0          | 0.428         | 0.1831       | 0.2565    | 0            | 0          |
| <i>Linear Discriminant Analysis</i>    | 0.428           | 0.485      | 0.428         | 0.1831       | 0.2565    | 0            | 0          |
| <i>Dummy Classifier</i>                | 0.428           | 0.5        | 0.428         | 0.1831       | 0.2565    | 0            | 0          |
| <i>Ada Boost Classifier</i>            | 0.4279          | 0.6434     | 0.4279        | 0.2339       | 0.258     | 0.001        | 0.012      |
| <i>SVM - Linear Kernel</i>             | 0.309           | 0          | 0.309         | 0.1803       | 0.2259    | -0.0459      | -0.0549    |
| <i>Naive Bayes</i>                     | 0.2601          | 0.6029     | 0.2601        | 0.3395       | 0.2119    | 0.0766       | 0.138      |
| <i>Quadratic Discriminant Analysis</i> | 0.2601          | 0.6029     | 0.2601        | 0.3395       | 0.2119    | 0.0766       | 0.138      |

**Obs.:** Resultados dos algoritmos de *machine learning* testados na pesquisa.

O treinamento se deu a partir da amostra de *accruals* de capital de giro (*Wc\_Acc*) no período selecionado como base para o treinamento dos algoritmos de *machine learning* (período entre 2010 (quarto trimestre) e 2011 (quarto trimestre)).

A partir desta amostra, simulou-se gerenciamento de resultados de forma aleatória equivalente a 1% da Variação dos Ativos Totais ( $VAT_{it} = (Assets_{it} - Assets_{it-1}) / Assets_{it-1}$ ) para 40% das observações da amostra selecionada para o treinamento dos algoritmos. A amostra final de treinamento se deu após a repetição deste procedimento 50 vezes.

**Fonte:** Dados da pesquisa.

A acurácia (*Accuracy*) é a medida de quantas previsões totais feitas pelo modelo estão corretas. Seu resultado representa a proporção de previsões verdadeiras (verdadeiros positivos e verdadeiros negativos) em relação ao número total de previsões. A acurácia fornece uma medida geral do desempenho do modelo em todas as classes. Similar ao *R*-quadrado, para regressões, utiliza-se a acurácia, quando se trata de problemas de classificação, como é o caso do presente trabalho. Nesse caso, uma acurácia de 0,8397 indica que o modelo previu corretamente as classes (*labels*) para, aproximadamente, 83,97% das amostras durante a validação cruzada (*cross-validation*). Este resultado representa um bom desempenho, mas é essencial analisar esta métrica em conjunto com as demais.

*AUC* (*Area Under the Curve*) é a área sob a curva *ROC* (*Receiver Operating Characteristic*) e mede a capacidade do modelo de distinguir entre classes positivas e negativas. Um valor de 0,965 sugere que o modelo possui excelente poder discriminatório.

Uma AUC de 1,0 indicaria um classificador perfeito, portanto 0,965 está muito próximo do desempenho perfeito.

**Recall**, também conhecido como sensibilidade ou taxa de verdadeiro positivo, mede a capacidade do modelo de identificar corretamente instâncias positivas (ocorrência do evento objeto de treinamento) dentre todas as instâncias positivas reais. Neste caso, o **recall** do modelo de 0,8397 indica que este identificou corretamente aproximadamente 83,97% das amostras de ocorrências reais. De forma geral, quanto mais próximo de 1 (máximo), melhor, especialmente quando se deseja minimizar falsos negativos.

A precisão (**Precision**) mede a proporção de previsões positivas verdadeiras em relação ao número total de instâncias positivas previstas, ou seja, a capacidade do modelo de classificar corretamente as instâncias positivas dentre todas as instâncias previstas como positivas. Com precisão de 0,8583, o modelo previu corretamente aproximadamente 85,83% das amostras identificadas como positivas. Isso indica que quando o modelo prevê uma classe positiva, ele está correto na maioria das vezes.

**F1** (*F1 score*) é a média harmônica entre a precisão (**Precision**) e sensibilidade (**Recall**), fornecendo uma medida equilibrada do desempenho de um modelo. Uma pontuação **F1** de 0,843 é uma boa métrica de desempenho geral, especialmente quando se deseja equilibrar precisão e sensibilidade. Indica uma relação razoável entre falsos positivos e falsos negativos.

A estatística **Kappa** (*Cohen's Kappa*) mede a concordância entre as previsões do modelo e os rótulos (*labels*) reais, ao mesmo tempo que contabiliza a concordância que seria esperada pelo acaso. Varia de -1 a 1, com 1 indicando concordância perfeita, 0 indicando concordância por acaso e valores negativos indicando concordância pior que a concordância ao acaso. Um valor **Kappa** de 0,7924 sugere concordância substancial entre as previsões do modelo e os rótulos verdadeiros.

O **MCC** (*Matthews Correlation Coefficient*) é uma métrica única que resume a qualidade de um modelo de classificação binária, levando em consideração tanto os verdadeiros positivos, os verdadeiros negativos, os falsos positivos e os falsos negativos, fornecendo uma medida equilibrada do desempenho da classificação. Varia de -1 a +1, onde +1 indica classificação perfeita, 0 indica classificação aleatória e -1 indica classificação inversa perfeita (previsões completamente erradas). É particularmente útil ao lidar com conjuntos de dados desequilibrados. Um valor de 0,7952 para **MCC** está próximo de 1, o que sugere que o algoritmo sob análise (*Decision Tree Classifier*) tem um bom desempenho geral em termos de classificação correta de instâncias positivas e negativas, ao mesmo tempo em que minimiza falsos positivos e falsos negativos.

#### 4.8.2. Desempenho do *Decision Tree Classifier* por Classe (*Label*)

Conforme salientado na Metodologia, diferente da hipótese utilizada por Dechow et al. (2012), esta pesquisa considera a possibilidade de intersecções entre os períodos de início e reversão do gerenciamento de resultados, o que implica em um conjunto de sete possíveis estados (classes 0 a 6) que representam os rótulos (*labels*) gerados pelo algoritmo.


Como o total de eventos de inclusão de gerenciamento artificial representa, no máximo, 40% da amostra para o treinamento, a classe 0 (ausência de gerenciamento) representa a maior parte da mesma (por volta de 60%). Em seguida com maior número de

observações, tem-se a classe 1 (início de gerenciamento), 2 (primeira reversão), 4 (início de gerenciamento e primeira reversão de gerenciamento anterior), 6 (início de gerenciamento e duas reversões de gerenciamentos anteriores), 3 (segunda e última reversão de gerenciamento anterior) e 5 (início de gerenciamento e última reversão de gerenciamento anterior). Esta ordem é importante para a análise pois, quanto mais eventos uma classe apresenta, maior é a capacidade do algoritmo “aprender” este padrão.

A Figura 9 apresenta a Matriz de Confusão para *Decision Trees* com simulações de gerenciamento de resultados equivalente a 1% da variação dos Ativos Totais para 40% das observações da amostra. A diagonal da matriz representa o percentual de acerto para cada classe, quando o evento realmente ocorreu (*True Positive*). Destaca-se, nesse contexto, o percentual de acerto quando se trata da classe 6, com predição correta de todas as observações positivas. O resultado se destaca por esta classe compreender os três eventos possíveis em termos de gerenciamento artificial (início de gerenciamento, reversão de 50% do gerenciamento iniciado no período anterior e outra reversão de 50% de gerenciamento iniciado há dois períodos anteriores). Esta intersecção dos três eventos tende a gerar nuances mais difíceis de se captar.

Apesar prever corretamente todas as ocorrências relativas à classe 6, o algoritmo classificou erroneamente, instancias relativas a todas as outras classes. Em especial, destacam-se as classes 5 e 4, para as quais todas as classificações incorretas foram identificadas como sendo classe 6 (24% e 15%, respectivamente).

Ainda em relação à diagonal da Matriz de Confusão (taxas de verdadeiro positivo), conforme relatado na Figura 1, a classe 0 (ausência de gerenciamento artificial) apresenta o segundo melhor resultado (86%), seguida das classes 1 e 4 (85%), 5 (76%), 3 (74%) e, por último, classe 2, com 73% de acertos.



**Obs.:** Matriz de Confusão para o algoritmo de *machine learning* selecionado para os testes nas regressões (*Decision Trees*).

O treinamento se deu a partir da amostra de *accruals* de capital de giro (*Wc\_Acc*) no período selecionado como base para o treinamento dos algoritmos de *machine learning* (período entre 2010 (quarto trimestre) e 2011 (quarto trimestre)).

A partir desta amostra, simulou-se gerenciamento de resultados de forma aleatória equivalente a 1% da Variação dos Ativos Totais ( $VAT_{it} = (Assets_{it} - Assets_{it-1}) / Assets_{it-1}$ ) para 40% das observações da amostra selecionada para o



treinamento dos algoritmos. A amostra final de treinamento se deu após a repetição deste procedimento 50 vezes.

Cada classe (*label*) representa uma configuração de valores para as *dummies* de inclusão e reversão de gerenciamento de resultados, conforme segue:

**Label 0:**  $P_{ML_{it}} = 0$ ;  $PR1_{ML_{it}} = 0$ ;  $PR2_{ML_{it}} = 0$   
**Label 1:**  $P_{ML_{it}} = 1$ ;  $PR1_{ML_{it}} = 0$ ;  $PR2_{ML_{it}} = 0$   
**Label 2:**  $P_{ML_{it}} = 0$ ;  $PR1_{ML_{it}} = 1$ ;  $PR2_{ML_{it}} = 0$   
**Label 3:**  $P_{ML_{it}} = 0$ ;  $PR1_{ML_{it}} = 0$ ;  $PR2_{ML_{it}} = 1$   
**Label 4:**  $P_{ML_{it}} = 1$ ;  $PR1_{ML_{it}} = 1$ ;  $PR2_{ML_{it}} = 0$   
**Label 5:**  $P_{ML_{it}} = 1$ ;  $PR1_{ML_{it}} = 0$ ;  $PR2_{ML_{it}} = 1$   
**Label 6:**  $P_{ML_{it}} = 1$ ;  $PR1_{ML_{it}} = 1$ ;  $PR2_{ML_{it}} = 1$

Onde:

$P_{ML_{it}}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão de gerenciamento induzido e 0, caso contrário;

$PR1_{ML_{it}}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão

de reversão de 50% do gerenciamento induzido no ano subsequente e 0, caso contrário;

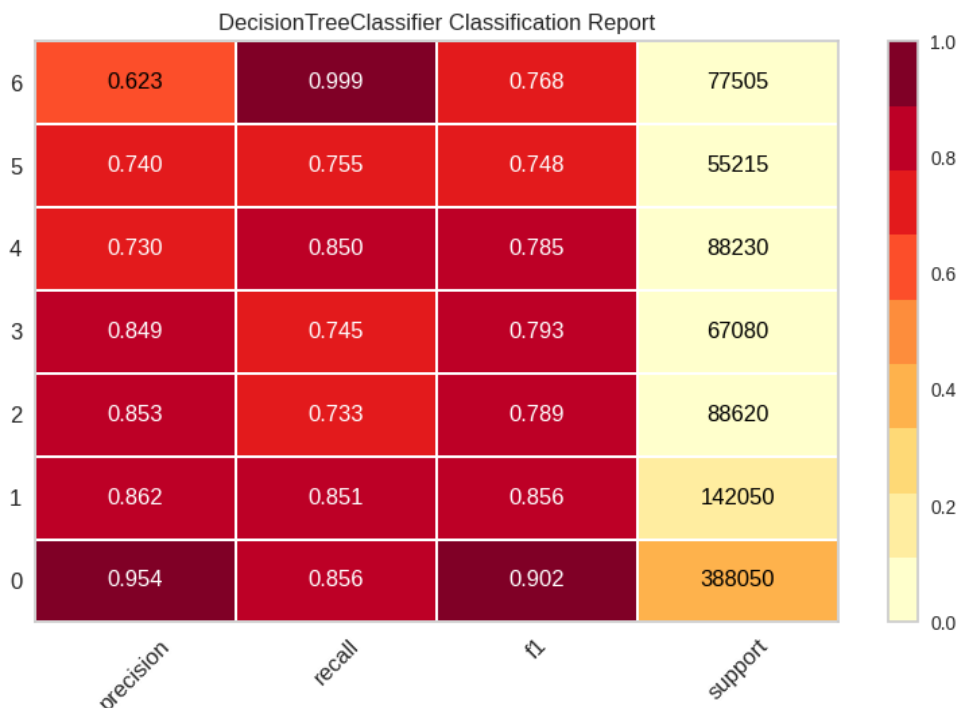
$PR2_{ML_{it}}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão

de reversão de 50% do gerenciamento induzido no segundo ano subsequente à indução e 0, caso contrário.

**Fonte:** Dados da pesquisa.

A Figura 10 apresenta as 7 classes avaliadas através de três medidas: **Precision**, **Recall** e **F1**. Como mencionado anteriormente, **Precision** se refere ao valor preditivo dos eventos objeto de treinamento, **Recall** indica a taxa de positivos verdadeiros e **F1** é a média harmônica das duas métricas anteriores.

**Figura 10:** Resultados do treinamento do *Decision Trees* para cada rótulo (*label*).



**Obs.:** Resultados do treinamento do algoritmo de *machine learning* selecionado para os testes nas regressões (*Decision Trees*), para cada rótulo (*label*).

O treinamento se deu a partir da amostra de *accruals* de capital de giro (*Wc\_Acc*) no período selecionado como base para o treinamento dos algoritmos de *machine learning* (período entre 2010 (quarto trimestre) e 2011 (quarto trimestre)).

A partir desta amostra, simulou-se gerenciamento de resultados de forma aleatória equivalente a 1% da Variação dos Ativos Totais ( $VAT_{it} = (Assets_{it} - Assets_{it-1}) / Assets_{it-1}$ ) para 40% das observações da amostra selecionada para o treinamento dos algoritmos. A amostra final de treinamento se deu após a repetição deste procedimento 50 vezes.

Cada classe (*label*) representa uma configuração de valores para as *dummies* de inclusão e reversão de gerenciamento de resultados, conforme segue:

**Label 0:**  $P_{ML_{it}} = 0; PR1_{ML_{it}} = 0; PR2_{ML_{it}} = 0$

**Label 1:**  $P_{ML_{it}} = 1; PR1_{ML_{it}} = 0; PR2_{ML_{it}} = 0$

**Label 2:**  $P_{ML_{it}} = 0; PR1_{ML_{it}} = 1; PR2_{ML_{it}} = 0$

**Label 3:**  $P_{ML_{it}} = 0; PR1_{ML_{it}} = 0; PR2_{ML_{it}} = 1$

**Label 4:**  $P_{ML_{it}} = 1; PR1_{ML_{it}} = 1; PR2_{ML_{it}} = 0$

**Label 5:**  $P_{ML_{it}} = 1; PR1_{ML_{it}} = 0; PR2_{ML_{it}} = 1$

**Label 6:**  $P_{ML_{it}} = 1; PR1_{ML_{it}} = 1; PR2_{ML_{it}} = 1$

Onde:

$P_{ML_{it}}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão de gerenciamento induzido e 0, caso contrário;

$PR1_{ML_{it}}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão

de reversão de 50% do gerenciamento induzido no ano subsequente e 0, caso contrário;

$PR2_{ML_{it}}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão

de reversão de 50% do gerenciamento induzido no segundo ano subsequente à indução e 0, caso contrário.

---

**Fonte:** Dados da pesquisa.

Como relatado através da Matriz de Confusão (Figura 9), a classe 6 apresentou uma sensibilidade quase perfeita (**Recall** de 0.999), ou seja, previu corretamente quase todas as ocorrências dos eventos referentes a esta classe, porém, identificou erroneamente eventos associados a outras classes como sendo do tipo 6, culminando em um resultado muito abaixo para a métrica de precisão (**Precision** de 0.623). Na média, porém, seu resultado foi satisfatório (**F1** de 0.768).

O contrário ocorre com as previsões para a classe 0: precisão mais alta do que a sensibilidade (**Precision** igual a 0.954 e 0.856 para **Recall**). Apesar da métrica para sensibilidade ter apresentado valor menor, a diferença entre as duas não foi tão grande quanto a observada para a classe 6 e, portanto, a média das duas métricas (**F1**) para a classe 0 é a maior dentre todas.

## 4.9. Resultados do Testes Utilizando Regressões

### 4.9.1. Resultados do Testes Utilizando os Modelos Base

Os resultados apurados nesta seção se referem à segunda etapa geral do trabalho, que visa a comparação entre os resultados das regressões de modelos clássicos de detecção de gerenciamento de resultados com base em *accruals* e os resultados dos mesmos modelos modificados pela inclusão de variáveis *dummy* geradas pelo algoritmo selecionado.

A Tabela 9 relata as médias dos coeficientes e suas estatísticas *t* e *R*-quadrado ajustado das mil regressões realizadas para os modelos base ( $MB_m$ ) em um cenário no qual 0,1% da amostra apresenta  $P_{it} = 1$ , com a inclusão de gerenciamento equivalente a 1% da variação dos Ativos Totais.

De forma geral, os resultados apontam para uma melhoria no poder de explicação dos modelos originais, visto o aumento substancial na média dos *R*-quadrado ajustados para os modelos que utilizam variáveis *dummy* geradas pelo algoritmo de *machine learning* (*Decision Tree*). Destaca-se, principalmente, a variação observada entre os Modelos Base 1 e 5 (modelo

Dechow e Dichev (2002) original e modificado), saindo de um  $R$ -quadrado ajustado de 1.8909% para 34.1089%.

**Tabela 9:** Médias dos coeficientes e suas estatísticas  $t$  e  $R$ -quadrado ajustado para o cenário de 0,1% de eventos.

| Modelo                | Param.     | Coef.   | $t$ -stat | Adj. $R^2$ | Modelo                | Param.     | Coef.   | $t$ -stat | Adj. $R^2$ |
|-----------------------|------------|---------|-----------|------------|-----------------------|------------|---------|-----------|------------|
| <b>MB<sub>1</sub></b> | $\alpha$   | 0.0042  | 5.2680    | 1.8909%    | <b>MB<sub>5</sub></b> | $\alpha$   | 0.0073  | 1.9184    | 34.1089%   |
|                       | $\beta_1$  | -       | -         |            |                       | $\beta_1$  | 0.1566  | 1.4922    |            |
|                       | $\beta_2$  | -       | -         |            |                       | $\beta_2$  | 0.2684  | 1.8395    |            |
|                       | $\beta_3$  | -       | -         |            |                       | $\beta_3$  | 0.0411  | 0.8216    |            |
|                       | $\gamma_1$ | 0.0938  | 2.8221    |            |                       | $\gamma_1$ | 0.0017  | 0.4431    |            |
|                       | $\gamma_2$ | -0.1648 | -3.3470   |            |                       | $\gamma_2$ | -0.1564 | -1.1715   |            |
|                       | $\gamma_3$ | 0.0184  | 0.8245    |            |                       | $\gamma_3$ | 0.0032  | 0.8363    |            |
| <b>MB<sub>2</sub></b> | $\alpha$   | 0.0004  | 0.3188    | 22.0002%   | <b>MB<sub>6</sub></b> | $\alpha$   | 0.0227  | 0.9533    | 35.4291%   |
|                       | $\beta_1$  | -       | -         |            |                       | $\beta_1$  | 0.1875  | 4.7954    |            |
|                       | $\beta_2$  | -       | -         |            |                       | $\beta_2$  | 0.3126  | 4.7282    |            |
|                       | $\beta_3$  | -       | -         |            |                       | $\beta_3$  | 0.0365  | 2.6592    |            |
|                       | $\gamma_1$ | -0.0025 | -0.5936   |            |                       | $\gamma_1$ | -0.0691 | -0.6664   |            |
|                       | $\gamma_2$ | 0.1711  | 13.3049   |            |                       | $\gamma_2$ | 0.0146  | 0.4394    |            |
| <b>MB<sub>3</sub></b> | $\alpha$   | -0.0010 | -0.7953   | 15.9036%   | <b>MB<sub>7</sub></b> | $\alpha$   | 0.0217  | 0.8912    | 35.3707%   |
|                       | $\beta_1$  | -       | -         |            |                       | $\beta_1$  | 0.1880  | 1.8718    |            |
|                       | $\beta_2$  | -       | -         |            |                       | $\beta_2$  | 0.3181  | 5.3595    |            |
|                       | $\beta_3$  | -       | -         |            |                       | $\beta_3$  | 0.0463  | 2.9437    |            |
|                       | $\gamma_1$ | 0.0061  | 1.3728    |            |                       | $\gamma_1$ | -0.0646 | -0.6069   |            |
|                       | $\gamma_2$ | 0.1677  | 10.3753   |            |                       | $\gamma_2$ | -0.0009 | 0.2042    |            |
| <b>MB<sub>4</sub></b> | $\alpha$   | 0.0011  | 0.9605    | 23.8001%   | <b>MB<sub>8</sub></b> | $\alpha$   | 0.0089  | 1.0972    | 44.0272%   |
|                       | $\beta_1$  | -       | -         |            |                       | $\beta_1$  | 0.2091  | 5.6930    |            |
|                       | $\beta_2$  | -       | -         |            |                       | $\beta_2$  | 0.3542  | 8.7900    |            |
|                       | $\beta_3$  | -       | -         |            |                       | $\beta_3$  | 0.0473  | 1.9021    |            |
|                       | $\gamma_1$ | -0.0039 | -0.9354   |            |                       | $\gamma_1$ | 0.0023  | -0.0913   |            |
|                       | $\gamma_2$ | 0.1716  | 13.6262   |            |                       | $\gamma_2$ | -0.0193 | -2.1004   |            |
|                       | $\gamma_3$ | 0.1164  | 4.9196    |            |                       | $\gamma_3$ | 0.0028  | 0.8732    |            |
|                       | $\gamma_4$ | -0.1564 | -4.6938   |            |                       | $\gamma_4$ | -0.2301 | -3.8899   |            |
|                       | $\gamma_5$ | 0.0051  | 0.2979    |            |                       | $\gamma_5$ | 0.0050  | 1.4628    |            |

**Obs.:** Médias dos coeficientes e suas estatísticas  $t$  e  $R$ -quadrado ajustado das mil regressões realizadas para os modelos base ( $MB_m$ ) em um cenário no qual 0,1% da amostra apresenta  $P_{it} = 1$ , com a inclusão de gerenciamento equivalente a 1% da variação dos Ativos Totais. Os modelos base ( $MB_m$ ) são descritos a seguir.

**MB<sub>1</sub>:** Modelo Dechow e Dichev (2002) em sua forma original:

$$Wc\_Acc_{it} = \alpha + \gamma_1 CFO_{it-1} + \gamma_2 CFO_{it} + \gamma_3 CFO_{it+1} + \delta_{1it};$$

Onde:

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}$$

$\Delta CA_{it}$  = variação no Ativo Circulante da empresa  $i$ , no período  $t$ ;

$\Delta CL_{it}$  = variação no Passivo Circulante da empresa  $i$ , no período  $t$ ;

$\Delta Cash_{it}$  = variação no Caixa da empresa  $i$ , no período  $t$ ;

$\Delta STD_{it}$  = variação nas dívidas de curto prazo da empresa  $i$ , no período  $t$ ; e

$Assets_{it-1}$  = Ativo Total da empresa  $i$ , no período anterior a  $t$ .

$CFO_{it-1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t-1$ ;

$CFO_{it}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t$ ;

$CFO_{it+1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t+1$ ;

**MB<sub>2</sub>:** Modelo Jones (1991) em sua forma original:

---


$$Wc\_Acc_{it} = \alpha + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \delta_{2it};$$

Onde:

- $PPE_{it}$  = Ativo Imobilizado da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ );  
 $\Delta Rev_{it}$  = Variação das Receitas da empresa  $i$ , no período  $t$ , dividida pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ ).

**MB<sub>3</sub>**: Modelo Jones (1991) modificado por Dechow et al. (1995), em sua forma original:

$$Wc\_Acc_{it} = \alpha + \gamma_1 PPE_{it} + \gamma_2 (\Delta Rev_{it} - \Delta Rec_{it}) + \delta_{3it};$$

Onde:

- $\Delta Rec_{it}$  = variação nos recebíveis da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ ).

**MB<sub>4</sub>**: Modelo McNichols (2002), em sua forma original:

$$Wc\_Acc_{it} = \alpha + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \gamma_3 CFO_{it-1} + \gamma_4 CFO_{it} + \gamma_5 CFO_{it+1} + \delta_{4it};$$

Os modelos base de 5 a 8 (**MB<sub>5</sub>**, **MB<sub>6</sub>**, **MB<sub>7</sub>**, **MB<sub>8</sub>**) diferenciam-se apenas pela modificação dos modelos básicos (**MB<sub>1</sub>**, **MB<sub>2</sub>**, **MB<sub>3</sub>** e **MB<sub>4</sub>**) via inclusão de variáveis *dummy* representativas de início de gerenciamento de resultado (e reversões) geradas por algoritmo de *machine learning* (neste caso, *Decision Trees*):

**MB<sub>5</sub>**: Modelo Dechow e Dichev (2002) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 CFO_{it-1} + \gamma_2 CFO_{it} + \gamma_3 CFO_{it+1} + \delta_{5it};$$

**MB<sub>6</sub>**: Modelo Jones (1991) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \delta_{6it};$$

**MB<sub>7</sub>**: Modelo Dechow et al. (1995) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 PPE_{it} + \gamma_2 (\Delta Rev_{it} - \Delta Rec_{it}) + \delta_{7it};$$

**MB<sub>8</sub>**: Modelo McNichols (2002) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \gamma_3 CFO_{it-1} + \gamma_4 CFO_{it} + \gamma_5 CFO_{it+1} + \delta_{8it};$$

Onde:

- $P\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão de gerenciamento induzido e 0, caso contrário;  
 $PR1\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão de reversão de 50% do gerenciamento induzido no ano subsequente e 0, caso contrário;  
 $PR2\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com previsão de reversão de 50% do gerenciamento induzido no segundo ano subsequente à indução e 0, caso contrário.

---

**Fonte:** Dados da pesquisa.

A Tabela 10 relata as médias dos coeficientes e suas estatísticas  $t$  e  $R$ -quadrado ajustado das mil regressões realizadas para os modelos base ( $MB_m$ ) em um cenário no qual 20% da amostra apresenta  $P_{it} = 1$ , com a inclusão de gerenciamento equivalente a 1% da variação dos Ativos Totais.

Da mesma forma como os resultados apresentados na Tabela 9 (cenário de 0,1% da amostra com gerenciamento induzido), os resultados apontam para uma melhoria no poder de explicação dos modelos originais, visto o aumento substancial na média dos  $R$ -quadrado ajustados para os modelos que utilizam variáveis *dummy* geradas pelo algoritmo de *machine learning* (*Decision Tree*). Destaca-se, principalmente, a variação observada entre os Modelos

Base 1 e 5 (modelo Dechow e Dichev (2002) original e modificado), saindo de um  $R$ -quadrado ajustado de 1.8551% para 30.2244%.

**Tabela 10:** Médias dos coeficientes e suas estatísticas  $t$  e  $R$ -quadrado ajustado para o cenário de 20% de eventos.

| Modelo                | Param.     | Coef.   | $t$ -stat | Adj. $R^2$ | Modelo                | Param.     | Coef.   | $t$ -stat | Adj. $R^2$ |
|-----------------------|------------|---------|-----------|------------|-----------------------|------------|---------|-----------|------------|
| <b>MB<sub>1</sub></b> | $\alpha$   | 0.0042  | 5.2682    | 1.8551%    | <b>MB<sub>5</sub></b> | $\alpha$   | 0.0079  | 2.0906    | 30.2244%   |
|                       | $\beta_1$  | -       | -         |            |                       | $\beta_1$  | 0.1596  | 1.9416    |            |
|                       | $\beta_2$  | -       | -         |            |                       | $\beta_2$  | 0.2140  | 1.0284    |            |
|                       | $\beta_3$  | -       | -         |            |                       | $\beta_3$  | 0.0432  | 0.3523    |            |
|                       | $\gamma_1$ | 0.0950  | 2.7962    |            |                       | $\gamma_1$ | 0.0016  | 0.4199    |            |
|                       | $\gamma_2$ | -0.1666 | -3.3081   |            |                       | $\gamma_2$ | -0.1533 | -1.2276   |            |
|                       | $\gamma_3$ | 0.0189  | 0.8332    |            |                       | $\gamma_3$ | 0.0031  | 0.8697    |            |
| <b>MB<sub>2</sub></b> | $\alpha$   | 0.0002  | 0.1437    | 22.9533%   | <b>MB<sub>6</sub></b> | $\alpha$   | 0.0206  | 0.8960    | 31.2499%   |
|                       | $\beta_1$  | -       | -         |            |                       | $\beta_1$  | 0.1904  | 2.7851    |            |
|                       | $\beta_2$  | -       | -         |            |                       | $\beta_2$  | 0.2378  | 2.8276    |            |
|                       | $\beta_3$  | -       | -         |            |                       | $\beta_3$  | 0.0324  | 2.7101    |            |
|                       | $\gamma_1$ | -0.0020 | -0.4866   |            |                       | $\gamma_1$ | -0.0601 | -0.5732   |            |
|                       | $\gamma_2$ | 0.1762  | 13.6578   |            |                       | $\gamma_2$ | 0.0178  | 0.5052    |            |
| <b>MB<sub>3</sub></b> | $\alpha$   | -0.0012 | -0.9759   | 16.7361%   | <b>MB<sub>7</sub></b> | $\alpha$   | 0.0192  | 0.8067    | 31.0931%   |
|                       | $\beta_1$  | -       | -         |            |                       | $\beta_1$  | 0.1910  | 2.9032    |            |
|                       | $\beta_2$  | -       | -         |            |                       | $\beta_2$  | 0.2442  | 5.2809    |            |
|                       | $\beta_3$  | -       | -         |            |                       | $\beta_3$  | 0.0439  | 3.0063    |            |
|                       | $\gamma_1$ | 0.0067  | 1.4967    |            |                       | $\gamma_1$ | -0.0537 | -0.4812   |            |
|                       | $\gamma_2$ | 0.1733  | 10.6611   |            |                       | $\gamma_2$ | 0.0003  | 0.2289    |            |
| <b>MB<sub>4</sub></b> | $\alpha$   | 0.0009  | 0.7809    | 24.7686%   | <b>MB<sub>8</sub></b> | $\alpha$   | 0.0079  | 0.9725    | 39.1673%   |
|                       | $\beta_1$  | -       | -         |            |                       | $\beta_1$  | 0.2126  | 8.0643    |            |
|                       | $\beta_2$  | -       | -         |            |                       | $\beta_2$  | 0.2716  | 10.4246   |            |
|                       | $\beta_3$  | -       | -         |            |                       | $\beta_3$  | 0.0490  | 4.1110    |            |
|                       | $\gamma_1$ | -0.0034 | -0.8264   |            |                       | $\gamma_1$ | 0.0076  | 0.0387    |            |
|                       | $\gamma_2$ | 0.1768  | 13.9870   |            |                       | $\gamma_2$ | -0.0146 | -1.8077   |            |
|                       | $\gamma_3$ | 0.1183  | 4.9713    |            |                       | $\gamma_3$ | 0.0026  | 0.8159    |            |
|                       | $\gamma_4$ | -0.1579 | -4.7121   |            |                       | $\gamma_4$ | -0.2199 | -3.5090   |            |
|                       | $\gamma_5$ | 0.0052  | 0.3009    | $\gamma_5$ | 0.0048                | 1.3954     |         |           |            |

**Obs.:** Médias dos coeficientes e suas estatísticas  $t$  e  $R$ -quadrado ajustado das mil regressões realizadas para os modelos base ( $MB_m$ ) em um cenário no qual 20% da amostra apresenta  $P_{it} = 1$ , com a inclusão de gerenciamento equivalente a 1% da variação dos Ativos Totais. Os modelos base ( $MB_m$ ) são descritos a seguir.

**MB<sub>1</sub>:** Modelo Dechow e Dichev (2002) em sua forma original:

$$Wc\_Acc_{it} = \alpha + \gamma_1 CFO_{it-1} + \gamma_2 CFO_{it} + \gamma_3 CFO_{it+1} + \delta_{1it};$$

Onde:

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}$$

$\Delta CA_{it}$  = variação no Ativo Circulante da empresa  $i$ , no período  $t$ ;

$\Delta CL_{it}$  = variação no Passivo Circulante da empresa  $i$ , no período  $t$ ;

$\Delta Cash_{it}$  = variação no Caixa da empresa  $i$ , no período  $t$ ;

$\Delta STD_{it}$  = variação nas dívidas de curto prazo da empresa  $i$ , no período  $t$ ; e

$Assets_{it-1}$  = Ativo Total da empresa  $i$ , no período anterior a  $t$ .

$CFO_{it-1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t-1$ ;

$CFO_{it}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t$ ;

$CFO_{it+1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t+1$ ;

**MB<sub>2</sub>:** Modelo Jones (1991) em sua forma original:

---


$$Wc\_Acc_{it} = \alpha + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \delta_{2it};$$

Onde:

- $PPE_{it}$  = Ativo Imobilizado da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ );  
 $\Delta Rev_{it}$  = Variação das Receitas da empresa  $i$ , no período  $t$ , dividida pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ ).

**MB<sub>3</sub>**: Modelo Jones (1991) modificado por Dechow et al. (1995), em sua forma original:

$$Wc\_Acc_{it} = \alpha + \gamma_1 PPE_{it} + \gamma_2 (\Delta Rev_{it} - \Delta Rec_{it}) + \delta_{3it};$$

Onde:

- $\Delta Rec_{it}$  = variação nos recebíveis da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ ).

**MB<sub>4</sub>**: Modelo McNichols (2002), em sua forma original:

$$Wc\_Acc_{it} = \alpha + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \gamma_3 CFO_{it-1} + \gamma_4 CFO_{it} + \gamma_5 CFO_{it+1} + \delta_{4it};$$

Os modelos base de 5 a 8 (**MB<sub>5</sub>**, **MB<sub>6</sub>**, **MB<sub>7</sub>**, **MB<sub>8</sub>**) diferenciam-se apenas pela modificação dos modelos básicos (**MB<sub>1</sub>**, **MB<sub>2</sub>**, **MB<sub>3</sub>** e **MB<sub>4</sub>**) via inclusão de variáveis *dummy* representativas de início de gerenciamento de resultado (e reversões) geradas por algoritmo de *machine learning* (neste caso, *Decision Trees*):

**MB<sub>5</sub>**: Modelo Dechow e Dichev (2002) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 CFO_{it-1} + \gamma_2 CFO_{it} + \gamma_3 CFO_{it+1} + \delta_{5it};$$

**MB<sub>6</sub>**: Modelo Jones (1991) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \delta_{6it};$$

**MB<sub>7</sub>**: Modelo Dechow et al. (1995) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 PPE_{it} + \gamma_2 (\Delta Rev_{it} - \Delta Rec_{it}) + \delta_{7it};$$

**MB<sub>8</sub>**: Modelo McNichols (2002) modificado:

$$Wc\_Acc_{it} = \alpha + \beta_1 P\_ML_{it} + \beta_2 PR1\_ML_{it} + \beta_3 PR2\_ML_{it} + \gamma_1 PPE_{it} + \gamma_2 \Delta Rev_{it} + \gamma_3 CFO_{it-1} + \gamma_4 CFO_{it} + \gamma_5 CFO_{it+1} + \delta_{8it};$$

Onde:

- $P\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com gerenciamento induzido e 0, caso contrário;  
 $PR1\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com reversão de 50% do gerenciamento induzido no ano subsequente e 0, caso contrário;  
 $PR2\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com reversão de 50% do gerenciamento induzido no segundo ano subsequente à indução e 0, caso contrário.

---

**Fonte:** Dados da pesquisa.

## 4.9.2. Resultados do Testes Utilizando os Modelos Gerais

Nesta seção descrevem-se os resultados alcançados com vistas à consecução da etapa da terceira etapa geral do trabalho: comparação dos resultados de regressões utilizando os resíduos encontrados na etapa anterior contra as *dummies* geradas por simulações. Da mesma forma, os resultados apurados se baseiam em dois cenários em termos de proporção da amostra com gerenciamento induzido: 0,1% e 20%.

A Tabela 11 apresenta o resultado dos 8 Modelos Gerais para a amostra com 0,1% das observações com gerenciamento induzido. Os Modelos Gerais de 1 a 4 utilizam, como variáveis independentes, os resíduos apurados através das regressões dos Modelos Base de 1 a 4 que, por sua vez, representam os 4 modelos de detecção de gerenciamento de resultados utilizados por esta pesquisa, em sua forma original. Espera-se que os resíduos dos modelos originais, se estes forem bem especificados, representem a parcela dos *accruals* totais que foi gerenciada pelas empresas e, portanto, quando regredidos contra variáveis *dummy* que indicam a ocorrência dos gerenciamentos induzidos artificialmente, espera-se que o poder explicativo dos modelos (avaliados através do *R*-quadrado ajustado) seja alto.

Porém, conforme evidente pelos resultados apresentados na Tabela 11, todos os Modelos Gerais baseados em modelos de detecção de gerenciamento originais possuem poder explicativo muito baixo. Tais resultados indicam que os resíduos dos modelos tradicionais testados não são boas *proxies* de gerenciamento de resultados.

Por outro lado, o que se espera em relação ao poder explicativo dos Modelos Gerais de 5 a 8, que utilizam os resíduos dos Modelos Base de 5 a 8 (modelos com *dummies* geradas por *machine learning*), é que apresentem valores muito baixos ou, até mesmo, nulos.

Os resultados apresentados na Tabela 11, referentes aos modelos  $MG_5$ ,  $MG_6$ ,  $MG_7$  e  $MG_8$ , confirmam as expectativas: todos os modelos apresentaram valores nulos para a média do *R*-quadrado ajustado, ou seja, os resíduos gerados pelos modelos que utilizam *dummies* geradas por *machine learning* não carregam informações que expliquem o comportamento do gerenciamento induzido pelas simulações. Desta forma, os resultados sugerem que tais informações foram capturadas pelas *dummies* utilizadas na etapa anterior.

**Tabela 11:** Médias dos coeficientes e estatísticas *t* e *R*-quadrado ajustado dos Modelos Gerais no cenário de 0,1% de eventos.

| Modelo | Param.    | Coef.  | <i>t</i> -stat | Adj. $R^2$ | Modelo | Param.    | Coef.   | <i>t</i> -stat | Adj. $R^2$ |
|--------|-----------|--------|----------------|------------|--------|-----------|---------|----------------|------------|
| $MG_1$ | $\beta_1$ | 0.0127 | 0.2900         | 0.0245%    | $MG_5$ | $\beta_1$ | -0.0049 | -0.1714        | 0.0000%    |
|        | $\beta_2$ | 0.0014 | -0.2187        |            |        | $\beta_2$ | -0.0099 | -0.5236        |            |
|        | $\beta_3$ | 0.0007 | -0.1786        |            |        | $\beta_3$ | -0.0086 | -0.4019        |            |
|        | $\alpha$  | 0.0000 | -0.0191        |            |        | $\alpha$  | 0.0002  | 0.0404         |            |
| $MG_2$ | $\beta_1$ | 0.0070 | 0.3172         | 0.0202%    | $MG_6$ | $\beta_1$ | -0.0049 | -0.2673        | 0.0000%    |
|        | $\beta_2$ | 0.0006 | -0.0852        |            |        | $\beta_2$ | -0.0107 | -0.6114        |            |
|        | $\beta_3$ | 0.0004 | -0.0505        |            |        | $\beta_3$ | -0.0097 | -0.5320        |            |
|        | $\alpha$  | 0.0000 | -0.0115        |            |        | $\alpha$  | 0.0002  | 0.0413         |            |
| $MG_3$ | $\beta_1$ | 0.0089 | 0.3625         | 0.0212%    | $MG_7$ | $\beta_1$ | -0.0047 | -0.2515        | 0.0000%    |
|        | $\beta_2$ | 0.0008 | -0.1044        |            |        | $\beta_2$ | -0.0107 | -0.5991        |            |
|        | $\beta_3$ | 0.0006 | -0.0632        |            |        | $\beta_3$ | -0.0096 | -0.5292        |            |
|        | $\alpha$  | 0.0000 | -0.0145        |            |        | $\alpha$  | 0.0002  | 0.0412         |            |
| $MG_4$ | $\beta_1$ | 0.0068 | 0.3152         | 0.0207%    | $MG_8$ | $\beta_1$ | -0.0060 | -0.2228        | 0.0000%    |
|        | $\beta_2$ | 0.0002 | -0.0837        |            |        | $\beta_2$ | -0.0107 | -0.5596        |            |
|        | $\beta_3$ | 0.0003 | -0.0496        |            |        | $\beta_3$ | -0.0094 | -0.4427        |            |
|        | $\alpha$  | 0.0000 | -0.0109        |            |        | $\alpha$  | 0.0002  | 0.0416         |            |

**Obs.:** Médias dos coeficientes e suas estatísticas *t* e *R*-quadrado ajustado das mil regressões realizadas para o modelo geral em um cenário no qual 0,1% da amostra apresenta  $P_{it} = 1$ , com a inclusão de gerenciamento equivalente a 1% da variação dos Ativos Totais. O Modelo Geral ( $MG_m$ ) é definido da seguinte forma:

$$MG_m = DAP_{mit} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

Sendo:

$DAP_{mit}$  = proxy de qualidade dos lucros dos modelos base ( $MB_m$ ), sendo o subscrito *m* referente ao modelo utilizado;

$P_{it}$  = variável *dummy* que assume valor 1 para observações com gerenciamento induzido e 0, caso contrário;

$PR1_{it}$  = variável *dummy* que assume valor 1 para observações com reversão de 50% do gerenciamento induzido no ano

---

subsequente e 0, caso contrário;  
 $PR2_{it}$  = variável *dummy* que assume valor 1 para observações com reversão de 50% do gerenciamento induzido no segundo ano subsequente à indução e 0, caso contrário.

Painel A relata as médias das estatísticas do modelo geral para cada variável independente ( $DAP_{mit}$ ) gerada a partir dos modelos base ( $MB_m$ ) descritos a seguir.

**MB<sub>1</sub>**: Modelo Dechow e Dichev (2002) em sua forma original:

$$Wc\_Acc_{it} = \gamma_{11} + \gamma_{12}CFO_{it-1} + \gamma_{13}CFO_{it} + \gamma_{14}CFO_{it+1} + \delta_{1it};$$

Onde:

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}$$

$\Delta CA_{it}$  = variação no Ativo Circulante da empresa *i*, no período *t*;  
 $\Delta CL_{it}$  = variação no Passivo Circulante da empresa *i*, no período *t*;  
 $\Delta Cash_{it}$  = variação no Caixa da empresa *i*, no período *t*;  
 $\Delta STD_{it}$  = variação nas dívidas de curto prazo da empresa *i*, no período *t*; e  
 $Assets_{it-1}$  = Ativo Total da empresa *i*, no período anterior a *t*.  
 $CFO_{it-1}$  = Fluxo de Caixa Operacional da empresa *i* no período *t-1*;  
 $CFO_{it}$  = Fluxo de Caixa Operacional da empresa *i* no período *t*;  
 $CFO_{it+1}$  = Fluxo de Caixa Operacional da empresa *i* no período *t+1*;

**MB<sub>2</sub>**: Modelo Jones (1991) em sua forma original:

$$Wc\_Acc_{it} = \gamma_{21} + \gamma_{22}PPE_{it} + \gamma_{23}\Delta Rev_{it} + \delta_{2it};$$

Onde:

$PPE_{it}$  = Ativo Imobilizado da empresa *i*, no período *t*, dividido pelos Ativos Totais da empresa *i* no período anterior (*t-1*);  
 $\Delta Rev_{it}$  = Variação das Receitas da empresa *i*, no período *t*, dividida pelos Ativos Totais da empresa *i* no período anterior (*t-1*).

**MB<sub>3</sub>**: Modelo Jones (1991) modificado por Dechow et al. (1995), em sua forma original:

$$Wc\_Acc_{it} = \gamma_{31} + \gamma_{32}PPE_{it} + \gamma_{33}(\Delta Rev_{it} - \Delta Rec_{it}) + \delta_{3it};$$

Onde:

$\Delta Rec_{it}$  = variação nos recebíveis da empresa *i*, no período *t*, dividido pelos Ativos Totais da empresa *i* no período anterior (*t-1*).

**MB<sub>4</sub>**: Modelo McNichols (2002), em sua forma original:

$$Wc\_Acc_{it} = \gamma_{41} + \gamma_{42}PPE_{it} + \gamma_{43}\Delta Rev_{it} + \gamma_{44}CFO_{it-1} + \gamma_{45}CFO_{it} + \gamma_{46}CFO_{it+1} + \delta_{4it};$$

Portanto, os modelos gerais apresentados no **Painel A** são representados da seguinte forma:

**MG<sub>1</sub>**:

$$DAP_{1it} = \delta_{1it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG<sub>2</sub>**:

$$DAP_{2it} = \delta_{2it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG<sub>3</sub>**:

$$DAP_{3it} = \delta_{3it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG<sub>4</sub>**:

$$DAP_{4it} = \delta_{4it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**Painel B** apresenta os mesmos resultados do **Painel A**, diferenciando-se apenas pela modificação dos modelos básicos (**MB<sub>1</sub>**, **MB<sub>2</sub>**, **MB<sub>3</sub>** e **MB<sub>4</sub>**) via inclusão de variáveis *dummy* representativas de início de gerenciamento de resultado (e reversões) geradas por algoritmo de *machine learning* (neste caso, *Decision Trees*):

**MB<sub>5</sub>**: Modelo Dechow e Dichev (2002) modificado:

$$Wc\_Acc_{it} = \gamma_{51} + \gamma_{52}P\_ML_{it} + \gamma_{53}PR1\_ML_{it} + \gamma_{54}PR2\_ML_{it} + \gamma_{55}CFO_{it-1} + \gamma_{56}CFO_{it} + \gamma_{57}CFO_{it+1} + \delta_{5it};$$

**MB<sub>6</sub>**: Modelo Jones (1991) modificado:

---



$$Wc\_Acc_{it} = \gamma_{61} + \gamma_{62}P\_ML_{it} + \gamma_{63}PR1\_ML_{it} + \gamma_{64}PR2\_ML_{it} + \gamma_{65}PPE_{it} + \gamma_{66}\Delta Rev_{it} + \delta_{6it};$$

**MB7:** Modelo Dechow et al. (1995) modificado:

$$Wc\_Acc_{it} = \gamma_{71} + \gamma_{72}P\_ML_{it} + \gamma_{73}PR1\_ML_{it} + \gamma_{74}PR2\_ML_{it} + \gamma_{75}PPE_{it} + \gamma_{76}(\Delta Rev_{it} - \Delta Rec_{it}) + \delta_{7it};$$

**MB8:** Modelo McNichols (2002) modificado:

$$Wc\_Acc_{it} = \gamma_{81} + \gamma_{82}P\_ML_{it} + \gamma_{83}PR1\_ML_{it} + \gamma_{84}PR2\_ML_{it} + \gamma_{85}PPE_{it} + \gamma_{86}\Delta Rev_{it} + \gamma_{87}CFO_{it-1} + \gamma_{88}CFO_{it} + \gamma_{89}CFO_{it+1} + \delta_{8it};$$

Onde:

$P\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com gerenciamento induzido e 0, caso contrário;

$PR1\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com reversão de 50% do gerenciamento induzido no ano subsequente e 0, caso contrário;

$PR2\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com reversão de 50% do gerenciamento induzido no segundo ano subsequente à indução e 0, caso contrário.

Portanto, os modelos gerais apresentados no **Painel B** são representados da seguinte forma:

**MG5:**

$$DAP_{5it} = \delta_{5it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG6:**

$$DAP_{6it} = \delta_{6it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG7:**

$$DAP_{7it} = \delta_{7it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG8:**

$$DAP_{8it} = \delta_{8it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**Fonte:** Dados da pesquisa.

Os resultados da Tabela 12 representam os resultados das regressões dos modelos gerais para o cenário de alta incidência de gerenciamento de resultados (20% da amostra). De forma geral, os resultados para este cenário corroboram os mencionados para o contexto de baixa manipulação (0,1% da amostra). Diferenciam-se apenas pelo aumento encontrado para as médias dos R-quadrados, porém, tal aumento se mostrou relativamente ínfimo.

**Tabela 12:** Médias dos coeficientes e estatísticas *t* e R-quadrado ajustado dos Modelos Gerais no cenário de 20% de eventos.

| Modelo          | Param.    | Coef.   | <i>t-stat</i> | Adj. R <sup>2</sup> | Modelo          | Param.    | Coef.   | <i>t-stat</i> | Adj. R <sup>2</sup> |
|-----------------|-----------|---------|---------------|---------------------|-----------------|-----------|---------|---------------|---------------------|
| MG <sub>1</sub> | $\beta_1$ | 0.0161  | 6.6216        | 0.8361%             | MG <sub>5</sub> | $\beta_1$ | -0.0035 | -0.2182       | 0.0075%             |
|                 | $\beta_2$ | 0.0008  | 0.3331        |                     |                 | $\beta_2$ | -0.0115 | -1.7706       |                     |
|                 | $\beta_3$ | 0.0001  | 0.0139        |                     |                 | $\beta_3$ | -0.0097 | -1.4775       |                     |
|                 | $\alpha$  | -0.0034 | -3.5592       |                     |                 | $\alpha$  | 0.0046  | 0.4611        |                     |
| MG <sub>2</sub> | $\beta_1$ | 0.0092  | 4.4574        | 0.3487%             | MG <sub>6</sub> | $\beta_1$ | -0.0033 | -0.2163       | 0.0024%             |
|                 | $\beta_2$ | -0.0004 | -0.1952       |                     |                 | $\beta_2$ | -0.0122 | -2.0405       |                     |
|                 | $\beta_3$ | 0.0003  | 0.1769        |                     |                 | $\beta_3$ | -0.0107 | -1.8135       |                     |
|                 | $\alpha$  | -0.0018 | -2.1683       |                     |                 | $\alpha$  | 0.0049  | 0.5475        |                     |
| MG <sub>3</sub> | $\beta_1$ | 0.0117  | 5.4320        | 0.5200%             | MG <sub>7</sub> | $\beta_1$ | -0.0031 | -0.1866       | 0.0001%             |
|                 | $\beta_2$ | -0.0002 | -0.1067       |                     |                 | $\beta_2$ | -0.0121 | -2.0107       |                     |
|                 | $\beta_3$ | 0.0003  | 0.1451        |                     |                 | $\beta_3$ | -0.0106 | -1.7914       |                     |
|                 | $\alpha$  | -0.0024 | -2.6853       |                     |                 | $\alpha$  | 0.0048  | 0.5361        |                     |
| MG <sub>4</sub> | $\beta_1$ | 0.0087  | 4.2583        | 0.3189%             | MG <sub>8</sub> | $\beta_1$ | -0.0045 | -0.3232       | 0.0034%             |
|                 | $\beta_2$ | -0.0006 | -0.3197       |                     |                 | $\beta_2$ | -0.0124 | -2.1656       |                     |
|                 | $\beta_3$ | 0.0002  | 0.0875        |                     |                 | $\beta_3$ | -0.0105 | -1.8113       |                     |
|                 | $\alpha$  | -0.0017 | -1.9864       |                     |                 | $\alpha$  | 0.0051  | 0.5800        |                     |

**Obs.:** Médias dos coeficientes e suas estatísticas  $t$  e R-quadrado ajustado das mil regressões realizadas para o modelo geral em um cenário no qual 20% da amostra apresenta  $P_{it} = 1$ , com a inclusão de gerenciamento equivalente a 1% da variação dos Ativos Totais. O Modelo Geral ( $MG_m$ ) é definido da seguinte forma:

$$MG_m = DAP_{mit} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

Sendo:

$DAP_{mit}$  = proxy de qualidade dos lucros dos modelos base ( $MB_m$ ), sendo o subscrito  $m$  referente ao modelo utilizado;

$P_{it}$  = variável *dummy* que assume valor 1 para observações com gerenciamento induzido e 0, caso contrário;

$PR1_{it}$  = variável *dummy* que assume valor 1 para observações com reversão de 50% do gerenciamento induzido no ano subsequente e 0, caso contrário;

$PR2_{it}$  = variável *dummy* que assume valor 1 para observações com reversão de 50% do gerenciamento induzido no segundo ano subsequente à indução e 0, caso contrário.

Painel A relata as médias das estatísticas do modelo geral para cada variável independente ( $DAP_{mit}$ ) gerada a partir dos modelos base ( $MB_m$ ) descritos a seguir.

**MB<sub>1</sub>:** Modelo Dechow e Dichev (2002) em sua forma original:

$$Wc\_Acc_{it} = \gamma_{11} + \gamma_{12}CFO_{it-1} + \gamma_{13}CFO_{it} + \gamma_{14}CFO_{it+1} + \delta_{1it};$$

Onde:

$$Wc\_Acc_{it} = (\Delta CA_{it} - \Delta CL_{it} - \Delta Cash_{it} + \Delta STD_{it}) / Assets_{it-1}$$

$\Delta CA_{it}$  = variação no Ativo Circulante da empresa  $i$ , no período  $t$ ;

$\Delta CL_{it}$  = variação no Passivo Circulante da empresa  $i$ , no período  $t$ ;

$\Delta Cash_{it}$  = variação no Caixa da empresa  $i$ , no período  $t$ ;

$\Delta STD_{it}$  = variação nas dívidas de curto prazo da empresa  $i$ , no período  $t$ ; e

$Assets_{it-1}$  = Ativo Total da empresa  $i$ , no período anterior a  $t$ .

$CFO_{it-1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t-1$ ;

$CFO_{it}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t$ ;

$CFO_{it+1}$  = Fluxo de Caixa Operacional da empresa  $i$  no período  $t+1$ ;

**MB<sub>2</sub>:** Modelo Jones (1991) em sua forma original:

$$Wc\_Acc_{it} = \gamma_{21} + \gamma_{22}PPE_{it} + \gamma_{23}\Delta Rev_{it} + \delta_{2it};$$

Onde:

$PPE_{it}$  = Ativo Imobilizado da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ );

$\Delta Rev_{it}$  = Variação das Receitas da empresa  $i$ , no período  $t$ , dividida pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ ).

**MB<sub>3</sub>:** Modelo Jones (1991) modificado por Dechow et al. (1995), em sua forma original:

$$Wc\_Acc_{it} = \gamma_{31} + \gamma_{32}PPE_{it} + \gamma_{33}(\Delta Rev_{it} - \Delta Rec_{it}) + \delta_{3it};$$

Onde:

$\Delta Rec_{it}$  = variação nos recebíveis da empresa  $i$ , no período  $t$ , dividido pelos Ativos Totais da empresa  $i$  no período anterior ( $t-1$ ).

**MB<sub>4</sub>:** Modelo McNichols (2002), em sua forma original:

$$Wc\_Acc_{it} = \gamma_{41} + \gamma_{42}PPE_{it} + \gamma_{43}\Delta Rev_{it} + \gamma_{44}CFO_{it-1} + \gamma_{45}CFO_{it} + \gamma_{46}CFO_{it+1} + \delta_{4it};$$

Portanto, os modelos gerais apresentados no **Painel A** são representados da seguinte forma:

**MG<sub>1</sub>:**

$$DAP_{1it} = \delta_{1it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG<sub>2</sub>:**

$$DAP_{2it} = \delta_{2it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG<sub>3</sub>:**

$$DAP_{3it} = \delta_{3it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG<sub>4</sub>:**

$$DAP_{4it} = \delta_{4it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**Painel B** apresenta os mesmos resultados do **Painel A**, diferenciando-se apenas pela modificação dos modelos básicos (**MB<sub>1</sub>**, **MB<sub>2</sub>**, **MB<sub>3</sub>** e **MB<sub>4</sub>**) via inclusão de variáveis *dummy* representativas de início de gerenciamento de resultado (e reversões) geradas por algoritmo de *machine learning* (neste caso, *Decision Trees*):

**MB<sub>5</sub>**: Modelo Dechow e Dichev (2002) modificado:

$$Wc\_Acc_{it} = \gamma_{51} + \gamma_{52}P\_ML_{it} + \gamma_{53}PR1\_ML_{it} + \gamma_{54}PR2\_ML_{it} + \gamma_{55}CFO_{it-1} + \gamma_{56}CFO_{it} + \gamma_{57}CFO_{it+1} + \delta_{5it};$$

**MB<sub>6</sub>**: Modelo Jones (1991) modificado:

$$Wc\_Acc_{it} = \gamma_{61} + \gamma_{62}P\_ML_{it} + \gamma_{63}PR1\_ML_{it} + \gamma_{64}PR2\_ML_{it} + \gamma_{65}PPE_{it} + \gamma_{66}\Delta Rev_{it} + \delta_{6it};$$

**MB<sub>7</sub>**: Modelo Dechow et al. (1995) modificado:

$$Wc\_Acc_{it} = \gamma_{71} + \gamma_{72}P\_ML_{it} + \gamma_{73}PR1\_ML_{it} + \gamma_{74}PR2\_ML_{it} + \gamma_{75}PPE_{it} + \gamma_{76}(\Delta Rev_{it} - \Delta Rec_{it}) + \delta_{7it};$$

**MB<sub>8</sub>**: Modelo McNichols (2002) modificado:

$$Wc\_Acc_{it} = \gamma_{81} + \gamma_{82}P\_ML_{it} + \gamma_{83}PR1\_ML_{it} + \gamma_{84}PR2\_ML_{it} + \gamma_{85}PPE_{it} + \gamma_{86}\Delta Rev_{it} + \gamma_{87}CFO_{it-1} + \gamma_{88}CFO_{it} + \gamma_{89}CFO_{it+1} + \delta_{8it};$$

Onde:

$P\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com gerenciamento induzido e 0, caso contrário;

$PR1\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com reversão de 50% do gerenciamento induzido no ano subsequente e 0, caso contrário;

$PR2\_ML_{it}$  = variável *dummy* gerada por algoritmo de *machine learning* que assume valor 1 para observações com reversão de 50% do gerenciamento induzido no segundo ano subsequente à indução e 0, caso contrário.

Portanto, os modelos gerais apresentados no **Painel B** são representados da seguinte forma:

**MG<sub>5</sub>**:

$$DAP_{5it} = \delta_{5it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG<sub>6</sub>**:

$$DAP_{6it} = \delta_{6it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG<sub>7</sub>**:

$$DAP_{7it} = \delta_{7it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

**MG<sub>8</sub>**:

$$DAP_{8it} = \delta_{8it} = \alpha + \beta_1 P_{it} + \beta_2 PR1_{it} + \beta_3 PR2_{it} + \varepsilon_{it}$$

Fonte: Dados da pesquisa.

#### 4.10. Considerações Finais

O presente trabalho teve por objetivo central levantar subsídios que contribuam para responder se as técnicas de *machine learning* são um caminho viável na busca de soluções para os problemas encontrados em modelos tradicionais de detecção de gerenciamento de resultados.

Um problema fundamental inerente aos modelos tradicionais de detecção de gerenciamento de resultados é que este não é mensurável diretamente. Desta forma, as atividades relacionadas a tal prática costumam ser de difícil distinção, dentro do universo de atividades normais dos negócios. Assim, a avaliação do desempenho real desses modelos pode ser problemática. A capacidade dos modelos na extração da parte discricionária dos *accruals* foi questionada em diversos estudos (por exemplo, Dechow et al., 1995; Xie (2001); Dechow et al., 2003). Thomas e Zhang (2000), por exemplo, concluíram que a maioria desses modelos apresentam desempenho pior do que apenas a simples suposição de que os *accruals* discricionários equivalem a 5% dos ativos totais.

Uma explicação para o fraco desempenho dos modelos é que os dados geralmente possuem bastante ruído (Höglund, 2012). Outra possível explicação é que a maioria dos modelos usa uma abordagem linear para modelar o processo de *accruals*, o que pode prejudicar o desempenho dos modelos, pois os resultados de vários estudos sugerem que tal processo, de fato, é não linear (Dechow, Sloan, & Sweeney, 1995; Jeter & Shivakumar, 1999; Kothari, Leone, & Wasley, 2005).

Dechow et al. (2012) propuseram um procedimento para abordar os problemas associados às técnicas tradicionais, incorporando as informações dos pesquisadores sobre a reversão dos *accruals* discricionários. Esta abordagem pode ser adaptada para utilização em todos os modelos tradicionais de detecção de gerenciamento de resultados com base em *accruals*.

Porém, como destacado pelos autores supracitados, este procedimento requer que o pesquisador identifique os períodos em que se espera que os *accruals* sejam manipulados, assim como os períodos com expectativa de suas reversões. Neste ponto, o presente trabalho pretendeu testar se a utilização de algoritmos de *machine learning* para a determinação de tais períodos promove melhorias no poder de explicação em relação aos modelos originais.

Para tanto, esta pesquisa atravessou três etapas principais:

1. treinamento e seleção do algoritmo de *machine learning* com o melhor desempenho;
2. comparação entre os resultados das regressões de modelos clássicos de detecção de gerenciamento de resultados com base em *accruals* e os resultados dos mesmos modelos modificados pela inclusão de variáveis *dummy* geradas pelo algoritmo selecionado na etapa 1; e
3. comparação dos resultados de regressões utilizando os resíduos encontrados na etapa 2 contra as *dummies* geradas por simulações.

De forma geral, os resultados encontrados no presente estudo indicam que as técnicas de *machine learning* representam, de fato, um caminho viável na busca de soluções para os problemas encontrados em modelos tradicionais de detecção de gerenciamento de resultados. Fundamentalmente, através do aumento no poder explicativo auferidos quando se utilizam variáveis *dummy* geradas pelo algoritmo de *machine learning* utilizado (*Decision Trees Classifier*) em relação aos modelos tradicionais em sua forma original.

## Referências

- Arya, A., Glover, J., & Sunder, S. (1998). Earnings management and the revelation principle. *Review of Accounting Studies*, 3(1–2), 7–34. <https://doi.org/10.1023/a:1009631714430>
- Ayers, B. C., Li, O. Z., & Yeung, P. E. (2011). Investor trading and the post-earnings-announcement drift. *The Accounting Review*, 86(2), 385-416.
- Bao, Y., Ke, B., Li, B., Yu, J., & Zhang, J. (2020b). Detecting accounting fraud in publicly traded U.S. firms using a machine learning approach. *Journal of Accounting Research*, 58(1), 199–235.
- Barber, B. M., & Odean, T. (2013). The Behavior of Individual Investors. In *Handbook of the Economics of Finance* (Vol. 2, Issue PB). Elsevier B.V. <https://doi.org/10.1016/B978-0-44-459406-8.00022-6>
- Basu, S. (1997). The conservatism principle and the asymmetric timeliness of earnings. *Journal of Accounting and Economics*, 31(3), 3–37. <https://doi.org/10.1177/0962280211413449>
- Blankespoor, E. et al. (2019). Why do individual investors disregard accounting information? The roles of information awareness and acquisition costs. *Journal of Accounting Research*, 57(1), pp.53–84.
- Barth, M.E., Li, K., McClure, C. (2019). Evolution in value relevance of accounting information.
- Bertomeu, J., Cheynel, E., Floyd, E., & Pan, W. (2020). Using machine learning to detect misstatements. *Review of Accounting Studies*, 26, 468–519.
- Binz, O., Schipper, K., & Standridge, K. (2022). What can analysts learn from artificial intelligence about fundamental analysis?. Available at SSRN 3745078.
- Dechow, P., Ge, W., & Schrand, C. (2010). Understanding earnings quality: A review of the proxies, their determinants and their consequences. *Journal of Accounting and Economics*, 50(2–3), 344–401. <https://doi.org/10.1016/j.jacceco.2010.09.001>
- Dechow, P. M., Richardson, S. A., & Tuna, I. (2003). Why Are Earnings Kinky? An Examination of the Earnings Management Explanation. *Review of Accounting Studies* 2003 8:2, 8(2), 355–384. <https://doi.org/10.1023/A:1024481916719>
- Dechow, P. M., Sloan, R. G., & Sweeney, A. P. (1995). Detecting earnings management. *The Accounting Review*, 70(2), 193–225.
- DeFond, M. L. (2010). Earnings quality research: Advances, challenges and future research. *Journal of Accounting and Economics*, 50(2–3), 402–409. <https://doi.org/10.1016/j.jacceco.2010.10.004>

- DeFond, M. L., & Jiambalvo, J. (1994). Debt covenant violation and manipulation of accruals. *Journal of Accounting and Economics*, 17(1–2), 145–176.
- Desai, M. A., Foley, C. F., & Hines Jr, J. R. (2004). A multinational perspective on capital structure choice and internal capital markets. *The Journal of finance*, 59(6), 2451-2487.
- Dimitropoulos, P. E., & Asteriou, D., 2010. Accounting relevance and speculative intensity: Empirical evidence from Greece. *Journal of Applied Accounting Research*, 11(3), 195–212. <https://doi.org/10.1108/09675421011088134>
- Dyckman, T.R. & Zeff, S.A., 2015. Accounting research: past, present, and future. *Abacus*, 51(4), pp.511–524.
- Ewert, R., & Wagenhofer, A. (2011). Earnings Management, Conservatism, and Earnings Quality. *Foundations and Trends in Accounting*, 6(2), 65–186. <https://doi.org/10.1561/14000000025>
- Ewert, R., & Wagenhofer, A. (2012). Earnings Quality Metrics and What They Measure. *SSRN Electronic Journal*, January. <https://doi.org/10.2139/ssrn.1697042>
- Fairfield, P. M., Whisenant, S., & Yohn, T. L. (2003). The Differential Persistence of Accruals and Cash Flows for Future Operating Income versus Future Profitability. *Review of Accounting Studies*, 8(2), 221–243. <https://doi.org/10.1023/A:1024413412176>
- Fama, E. F. (1970). American Finance Association Efficient Capital Markets : A Review of Theory and Empirical Work Author ( s ): Eugene F . Fama Source : The Journal of Finance , Vol . 25 , No . 2 , Papers and Proceedings of the Twenty- Eighth Annual Meeting of the American. *The Journal of Finance*, 25(2), 383–417.
- Fama, E. F. (1991). Efficient Capital Markets: II The comments of Fischer Black. *The Journal of Finance*, XLVI(5), 1575–1617.
- Fields, T. D., Lys, T. Z., & Vincent, L. (2001). Empirical research on accounting choice. *Journal of Accounting and Economics*, 31(1–3), 255–307. [https://doi.org/10.1016/S0165-4101\(01\)00028-3](https://doi.org/10.1016/S0165-4101(01)00028-3)
- Gerakos, J.J., Richard Hahn, P., Kovrijnykh, A., Zhou, F. (2016). Prediction versus inducement and the informational efficiency of going concern opinions. Available at SSRN 2802971.
- Grinblatt, M., & Keloharju, M. (2009). Sensation seeking, overconfidence, and trading activity. *The Journal of Finance*, 64(2), 549-578.
- Hirshleifer, D. A., Myers, J. N., Myers, L. A., & Teoh, S. H., 2008. Do individual investors cause post-earnings announcement drift? Direct evidence from personal trades. *The Accounting Review*, 83(6), 1521-1550.
- Hirshleifer, D., & Teoh, S. H. (2003). Limited attention, information disclosure, and financial reporting. *Journal of accounting and economics*, 36(1-3), 337-386.

- Jaggi, B., & Lee, P. (2002). Earnings management response to debt covenant violations and debt restructuring. *Journal of Accounting, Auditing and Finance*, 17(4), 295–324.
- Jeter, D. C., & Shivakumar, L. (1999). Cross-sectional estimation of abnormal accruals using quarterly and annual data: effectiveness in detecting event-specific earnings management. *Accounting and Business Research*, 29(4), 299–319.  
<https://doi.org/10.1080/00014788.1999.9729590>
- Kang, S. H., & Sivaramakrishnan, K. (1995). Issues in testing earnings management and an instrumental variable approach. *Journal of accounting Research*, 33(2), 353–367.
- Kothari, S. P., Leone, A. J., & Wasley, C. E. (2005). Performance matched discretionary accrual measures. *Journal of Accounting and Economics*, 39(1), 163–197.  
<https://doi.org/10.1016/j.jacceco.2004.11.002>
- Khan, M. (2008). Are accruals mispriced? Evidence from tests of an intertemporal capital asset pricing model. *Journal of Accounting and Economics* 45, 55–77.
- Kraft, A., Leone, A., Wasley, C. (2006). An analysis of the theories and explanations offered for the mispricing of accruals and accrual components. *Journal of Accounting Research* 44, 297–339.
- Lee, C. M. (1992). Earnings news and small traders: An intraday analysis. *Journal of Accounting and Economics*, 15(2-3), 265-302.
- Li, F. (2010). The information content of forward-looking statements in corporate filings—A naïve Bayesian machine learning approach. *Journal of Accounting Research*, 48(5), 1049-1102.
- Mandelbrot, B. B., & Hudson, R. L. (2010). *The (mis) behaviour of markets: a fractal view of risk, ruin and reward*. Profile books.
- Maines, L. A., & Hand, J. R. (1996). Individuals' perceptions and misperceptions of time series properties of quarterly earnings. *Accounting Review*, 317-336.
- McNichols, M. F. (2000). Research design issues in earnings management studies. *Journal of Accounting and Public Policy* 19(4–5). [https://doi.org/10.1016/S0278-4254\(00\)00018-1](https://doi.org/10.1016/S0278-4254(00)00018-1)
- Pavalko, R. M., 2001. *Problem gambling and its treatment: An introduction*. Charles C Thomas Publisher.
- Perols, J. L. (2011). Financial statement fraud detection: An analysis of statistical and machine learning algorithms. *Auditing: A Journal of Practice & Theory*, 30(2), 19–50.
- Perols, J. L., Bowen, R. M., Zimmermann, C., & Samba, B. (2017). Finding needles in a haystack: Using data analytics to improve fraud prediction. *The Accounting Review*, 92(2), 221–245.
- Richardson, S. A., Sloan, R. G., Soliman, M. T., & Tuna, I. (2006). The Implications of Accounting Distortions and Growth for Accruals and Profitability. *Accounting Review*, 81(3), 713–743.

- Shiller, R. J. (2005). Behavioral economics and institutional innovation. *Southern Economic Journal*, 72(2), 269-283.
- Sloan, R. G. (1996). Do Stock Prices Fully Refelct Information in Accruals and Cash Flows About Future Earnings? *The Accounting Review*, 71(3), 289–315.
- Statman, M., 2002. Lottery players/stock traders. *Financial Analysts Journal*, 58(1), 14-21.
- Sun, T. (2019). Applying deep learning to audit procedures: An illustrative framework. *Accounting Horizons*, 33(3), 89–109.
- Taylor, D. (2011). *Individual investors and corporate earnings* (Doctoral dissertation, Stanford University).
- Teoh, S. H., Welch, I., & Wong, T. J. (1998). Earnings management and the long-run market performance of initial public offerings. *Journal of Financial Economics*, 53(6), 1935–1974.
- Thomas, J., & Zhang, X. (2000). Identifying unexpected accruals: A comparison of current approaches. *Journal of Accounting and Public Policy*, 19(4–5), 347–376.
- Van Tendeloo, B., & Vanstraelen, A. (2005). Earnings management under German GAAP versus IFRS. *European Accounting Review*, 14(1), 155–180.
- Watts, R. L. (2003). Conservatism in Accounting Part I: Explanations and Implications. *Accounting Horizons*, 17(3), 207–221. <https://doi.org/10.2308/ACCH.2003.17.3.207>
- Watts, R. L., & Zimmerman, J. L. (1986). *Positive Accounting Theory*. Prentice-Hall Inc.
- Xie, H. (2001). The Mispricing of Abnormal Accruals. *The Accounting Review*, 76(3), 357–373. <https://doi.org/10.2308/ACCR.2001.76.3.357>
- Zhang, X. F. (2007). Accruals, investment, and the accrual anomaly. *The Accounting Review*, 82(5), 1333-1363.
- Zuckerman, M. (1994). Impulsive unsocialized sensation seeking: The biological foundations of a basic dimension of personality.



## 5. Considerações Finais

O estudo abordou profundamente a complexidade do gerenciamento de resultados nos contratos de agência, oferecendo soluções inovadoras para os desafios enfrentados pelos modelos tradicionais. O primeiro artigo explorou a eficácia da Rede Neural Artificial (RNA) na correção de problemas em modelos de gerenciamento de resultados. Demonstrou-se que a RNA supera os limites dos modelos lineares ao aprender estruturas não-lineares complexas, melhorando significativamente a precisão na mensuração do gerenciamento.

No segundo artigo, investigamos a reversão dos *accruals* de capital de giro em empresas brasileiras de capital aberto. Os resultados destacaram as limitações dos modelos tradicionais, revelando que mesmo os mais robustos não conseguiram capturar com precisão o gerenciamento realista. Este estudo ressaltou a necessidade de melhorar as técnicas de estimativa dos modelos de *accruals* para uma representação mais fiel da realidade econômica.

O terceiro artigo explorou a aplicação de algoritmos de *machine learning* na detecção de gerenciamento de resultados. Ao comparar os modelos tradicionais com variáveis *dummy* geradas por algoritmos, revelamos um aumento significativo no poder explicativo. Isso sugere que as técnicas de *machine learning* oferecem uma rota promissora para aprimorar a detecção de atividades discricionárias.

Em síntese, este conjunto de estudos forneceu contribuições valiosas ao campo, destacando a importância da integração entre ciência contábil e tecnologia da informação. As descobertas indicam que a aplicação de métodos não-lineares, como RNA e algoritmos de *machine learning*, oferece soluções promissoras para os desafios persistentes na detecção e mensuração do gerenciamento de resultados. Estes resultados oferecem uma nova perspectiva para futuras pesquisas, sugerindo a exploração de uma gama mais ampla de técnicas de inteligência artificial em modelos de qualidade da informação contábil, marcando um avanço significativo em pesquisas neste campo da contabilidade.