



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)

ROBERT MUZY FURTADO

**OBJETIVANDO A SUBJETIVIDADE:**  
***Achievement drive e estratégias gerenciais agressivas***

Brasília – DF

2024

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

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

Professor Doutor Lucio Remuzat Rennó Junior  
**Decano de Pós-Graduação**

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

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

Professor Doutor Jomar Miranda Rodrigues  
**Coordenador do Programa de Pós-Graduação em Ciências Contábeis**

ROBERT MUZY FURTADO

**OBJETIVANDO A SUBJETIVIDADE:**

***Achievement drive e estratégias gerenciais agressivas***

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. Dr. Paulo Roberto Barbosa  
Lustosa

Área de Concentração: Mensuração Contábil.

Linha de Pesquisa: Contabilidade e Mercado Financeiro.

Brasília – DF

2024

ROBERT MUZY FURTADO

**OBJETIVANDO A SUBJETIVIDADE:**  
*Achievement drive e estratégias gerenciais agressivas*

Tese submetida ao Programa de Pós-Graduação em Ciências Contábeis como requisito parcial para a obtenção do título de Doutor em Ciências Contábeis.

BANCA EXAMINADORA

---

Prof. Dr. Paulo Roberto Barbosa Lustosa  
Universidade de Brasília – UnB  
Orientador

---

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

---

Prof. Dr. Roberto Carlos Klann  
Universidade Regional de Blumenau – FURB  
Examinador Externo

---

Prof. Dr. Paulo Augusto Pettenuzzo de Britto  
Universidade de Brasília – UnB  
Examinador Interno

---

Prof. Dr. Rodrigo de Souza Gonçalves  
Universidade de Brasília – UnB  
Examinador Suplente

Brasília/DF, 22 de outubro de 2024.

## RESUMO

A era do big data apresenta reflexos cada vez mais significativos na prática e na literatura contábil, fornecendo ferramentas tecnológicas para a aplicação e a produção de novos conhecimentos. Dentre suas principais vantagens, estão o aumento da transparência e a melhoria da qualidade das informações, que podem ser ampliadas mais facilmente para dados além dos números, possibilitando análises sofisticadas de dados não financeiros, como textos, vídeos, áudios e imagens. Esta tese foca nas contribuições desse fenômeno para as pesquisas comportamentais em contabilidade, provocando uma reflexão acerca de como a crescente aplicação da ciência de dados na pesquisa pode auxiliar na descrição e previsão mais robusta e confiável do comportamento do usuário. A tese foi estruturada em três artigos. A literatura revisada no primeiro artigo destaca a busca das pesquisas em contabilidade comportamental pela compreensão dos fatores subjetivos individuais que interferem nas reações a estímulos do ambiente. Discutem-se os avanços proporcionados pelas novas tecnologias, que possibilitam a medição de fatores internos em grandes amostras não invasivas, analisando-se simultaneamente as interações entre o ambiente e os indivíduos, com base em teorias de distintos campos de conhecimento. Os dois artigos empíricos subsequentes investigam o efeito de um fator interno subjetivo – o *achievement drive* – nas escolhas contábeis e estratégias gerenciais adotadas pelos executivos. Utilizando visão computacional, uma ferramenta de inteligência artificial, essas características comportamentais foram mensuradas por meio de imagens faciais de diretores de empresas de ramos diversos no mercado norte americano. Os resultados dos artigos empíricos indicam que tanto o planejamento tributário quanto o gerenciamento de resultados estão relacionados com o *achievement drive*, sugerindo que essa medida pode influenciar decisões corporativas arriscadas. Além de contribuir para o entendimento dos traços comportamentais que moldam as decisões gerenciais, esta tese oferece uma base metodológica robusta para ampliar o uso de novas tecnologias nas pesquisas contábeis e comportamentais.

**Palavras-chave:** Contabilidade comportamental. Big data. *Achievement drive*. Agressividade fiscal. Gerenciamento de resultados

## ABSTRACT

The era of big data is increasingly impacting accounting practice and literature, providing technological tools for the application and production of new knowledge. Among its main advantages are enhanced transparency and improved information quality, which can be extended beyond numerical data, enabling sophisticated analyses of non-financial data such as text, videos, audio, and images. This thesis focuses on the contributions of this phenomenon to behavioural accounting research, prompting a reflection on how the growing application of data science in research can assist in providing a more robust and reliable description and prediction of user behaviour. The thesis is structured into three articles. The literature reviewed in the first article highlights the efforts in behavioural accounting research to understand the individual subjective factors that influence reactions to environmental stimuli. It discusses the advances brought by new technologies, which allow for the measurement of internal factors in large, non-invasive samples, while simultaneously analysing the interactions between environment and individuals based on theories from different fields of knowledge. The two subsequent empirical articles investigate the effect of an internal subjective factor – achievement drive – on accounting choices and managerial strategies adopted by executives. Using computer vision, an artificial intelligence tool, these behavioural characteristics were measured through facial images of executives from various industries in the North American market. The findings of the empirical articles indicate that both tax planning and earnings management are associated with achievement drive, suggesting that this measure may influence risky corporate decisions. In addition to contributing to the understanding of behavioural traits that shape managerial decisions, this thesis provides a robust methodological basis to expand the use of new technologies in accounting and behavioural research.

**Keywords:** Behavioural accounting. Big data. Achievement drive. Tax aggressiveness. Earnings management.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Libby box da pesquisa.....	14
Figura 2 – Poliedros inscritos em esfera.....	31
Figura 3 – Diagrama da estrutura multinível usada no estudo .....	43
Figura 4 – Efeitos marginais da relação tratamento x período .....	75
Figura 5 – Efeitos marginais da relação tratamento x períodos t-1 a t+1 .....	82
Figura 6 – Efeitos marginais da relação tratamento x períodos t-1 a t+2.....	83

## LISTA DE TABELAS

Tabela 1 – Amostra da pesquisa.....	39
Tabela 2 – Variáveis dependentes por setor.....	40
Tabela 3 – Resumo estatístico.....	44
Tabela 4 – Matriz de correlação e teste VIF (Variance Inflation Factor).....	46
Tabela 5 – Efeito da fWHR do CEO na agressividade tributária.....	47
Tabela 6 – Efeito da fWHR do CFO na agressividade tributária.....	50
Tabela 7 – Estimção do efeito da fWHR do CEO com coeficientes padronizados.....	52
Tabela 8 – Estimção do efeito da fWHR do CFO com coeficientes padronizados.....	53
Tabela 9 – Estimção do efeito da fWHR com modelagem de três níveis.....	55
Tabela 10 – Efeito do tempo de mandato na agressividade tributária.....	56
Tabela 11 – Variáveis de controle.....	67
Tabela 12 – Resumo estatístico e matriz de correlação.....	70
Tabela 13 – Resumo estatístico da fWHR e do mandato do CEO.....	71
Tabela 14 – Comparação entre grupos de controle e de tratamento.....	72
Tabela 15 – Comparação entre períodos pré e pós rotatividade de CEO.....	73
Tabela 16 – Diferenças em diferenças após pareamento.....	74
Tabela 17 – Estimção com modelagem multinível.....	78
Tabela 18 – Medidas alternativas de REM.....	80
Tabela 19 – Diferenças em diferenças com períodos alternativos.....	81
Tabela 20 – Efeito diferencial no aumento e na redução dos resultados.....	84



## LISTA DE ABREVIATURAS E SIGLAS

AAER	<i>Accounting and Auditing Enforcement Releases</i>
AIC	<i>Akaike Information Criterion</i>
BIC	<i>Bayesian Information Criterion</i>
BTD	<i>Book-Tax Differences</i>
CEO	<i>Chief Executive Officer</i>
CETR	<i>Cash Effective Tax Rate</i>
CFO	<i>Chief Financial Officer</i>
DACC	<i>Discretionary Accruals</i>
DiD	<i>Difference-in-Difference</i>
DP	Desvio Padrão
EBITDA	<i>Earnings Before Interests, Taxes, Depreciation and Amortization Expenses</i>
ETR	<i>Effective Tax Rate</i>
fWHR	<i>facial width-to-height ratio</i>
GAAP	<i>Generally Accepted Accounting Principles</i>
HLM	<i>Hierarchical Linear Model</i>
MQO	Mínimos Quadrados Ordinários
PSM	<i>Propensity-Score Matching</i>
REM	<i>Real Earnings Management</i>
ROA	<i>Return on Assets</i>
SEC	<i>Securities and Exchange Commission</i>
VIF	<i>Variance Inflation Factor</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>12</b>
<b>2</b>	<b>CONTABILIDADE COMPORTAMENTAL NA ERA DO BIG DATA: UM ESTUDO TEÓRICO .....</b>	<b>17</b>
2.1	Introdução .....	17
2.2	Da primeira infância à busca pela identidade.....	19
2.3	A busca pelos fatores subjetivos que interferem no comportamento.....	20
2.4	Indo além das teorias psicológicas e sociológicas.....	22
2.5	Big data e seus efeitos na pesquisa comportamental.....	25
2.5.1	Características do big data .....	26
2.5.2	Riscos, desafios e oportunidades.....	27
2.5.3	Vantagens perante os métodos tradicionais .....	29
2.5.4	Objetivando a subjetividade .....	30
2.6	Conclusões .....	32
<b>3</b>	<b>ACHIEVEMENT DRIVE E AGRESSIVIDADE FISCAL: UMA ANÁLISE EMPÍRICA UTILIZANDO FWHR.....</b>	<b>35</b>
3.1	Introdução .....	35
3.2	Revisão da Literatura.....	36
3.3	Procedimentos metodológicos.....	38
3.3.1	Dados e Amostra .....	38
3.3.2	Medidas de agressividade fiscal.....	39
3.3.3	Especificação do modelo de efeitos fixos .....	41
3.3.4	Especificação do modelo multinível .....	42
3.4	Resultados empíricos.....	43
3.4.1	Relação entre fWHR do CEO e agressividade fiscal corporativa.....	47
3.4.2	Análise do efeito da fWHR do CFO.....	49
3.4.3	Testes de robustez .....	54
3.4.3.1.	Modelagem multinível .....	54
3.4.3.2.	Tempo de mandato e subsequente aumento de agressividade.....	56
3.5	Conclusões .....	57
<b>4</b>	<b>GERENCIAMENTO DE RESULTADOS E O IMPACTO DO ACHIEVEMENT DRIVE.....</b>	<b>59</b>
4.1	Introdução .....	59
4.2	Revisão da literatura .....	60
4.2.1	Teoria dos escalões superiores e gerenciamento de resultados .....	61
4.2.2	Achievement drive, testosterona e estrutura facial.....	62
4.3	Desenho da pesquisa.....	63
4.3.1	Construção da amostra .....	63
4.3.2	Variáveis dependentes.....	63
4.3.3	Grupos de Controle e Tratamento .....	65
4.3.4	Pareamento.....	66

4.3.5	<i>Modelo de efeitos fixos</i> .....	66
4.3.6	<i>Modelo multinível ou hierárquico</i> .....	68
<b>4.4</b>	<b>Principais resultados empíricos</b> .....	<b>69</b>
4.4.1	<i>Estatística descritiva</i> .....	69
4.4.2	<i>Testes univariados</i> .....	71
4.4.3	<i>Diferenças em diferenças com pareamento</i> .....	73
4.4.4	<i>Teste de robustez</i> .....	77
<b>4.5</b>	<b>Testes adicionais</b> .....	<b>79</b>
4.5.1	<i>Desagregação das decisões operacionais</i> .....	79
4.5.2	<i>Reavaliação dos períodos de mudança de CEO</i> .....	80
4.5.3	<i>Teste com isolamento de accruals positivos e negativos</i> .....	83
<b>4.6</b>	<b>Conclusões</b> .....	<b>85</b>
<b>5</b>	<b>CONSIDERAÇÕES FINAIS</b> .....	<b>86</b>
	<b>REFERÊNCIAS</b> .....	<b>89</b>
	<b>APÊNDICE A – PROCEDIMENTOS ADOTADOS PARA O CÁLCULO DA FWHR</b> .....	<b>100</b>
	<b>APÊNDICE B – CONSTRUÇÃO E DEFINIÇÃO DAS VARIÁVEIS</b> .....	<b>102</b>

## 1 INTRODUÇÃO

Historicamente, a tentativa de correlacionar características físicas com tendências comportamentais remonta a práticas pseudocientíficas como a frenologia e a antropologia física, que buscavam prever a propensão a comportamentos antissociais, incluindo a criminalidade<sup>1</sup>. Essas disciplinas ganharam popularidade no século XIX, refletindo um antigo interesse na relação entre a fisionomia e o comportamento humano. Cientistas como Cesare Lombroso, conhecido como o pai da criminologia moderna, propuseram teorias que sugeriam que certas características físicas, incluindo o tamanho e forma do crânio, estavam ligadas à predisposição para o crime, teorias que encontraram eco em algumas comunidades científicas da época (Levine, 2010).

Com o avanço das ciências e da metodologia de pesquisa, tais práticas foram amplamente desacreditadas e rotuladas como pseudociências durante os séculos XIX e XX. A comunidade científica moderna, junto com a sociedade em geral, rejeitou essas teorias por não terem base científica sólida e por serem racialmente enviesadas e discriminatórias. Esses discursos, além de imprecisos, foram usados para justificar políticas racistas e eugenistas, contribuindo para injustiças sociais e violações dos direitos humanos (André, 2018; Arias & Walter, 2018; Zola-Morgan, 1995).

Em tempos mais recentes, a pesquisa sobre a relação entre a razão da largura e altura da face (*facial width-to-height ratio* – fWHR) e comportamentos tem recebido atenção crescente. Estudos sugerem que uma fWHR mais alta pode estar associada a níveis mais elevados de testosterona, influenciando traços comportamentais como agressividade, competitividade e propensão ao risco (Jia et al., 2014; Kamiya et al., 2019; Lefevre et al., 2013). Contudo, ao contrário das doutrinas anteriores, a pesquisa contemporânea sobre fWHR e comportamento busca uma compreensão mais sólida, fundamentada em genética, endocrinologia e psicologia, com uma postura ética rigorosa. Pesquisadores da área têm enfatizado a necessidade de evitar conclusões precipitadas e generalizações que possam promover estereótipos ou discriminação (Carré et al., 2013; Durkee & Ayers, 2021).

Nesse sentido, a presente tese insere-se no campo da contabilidade comportamental e explorará o efeito de estratégias gerenciais influenciadas por aspectos biológicos e psicológicos, como os traços comportamentais e biométricos de líderes empresariais. As limitações dos métodos tradicionais de pesquisa, como entrevistas e questionários, tornam-se evidentes

---

<sup>1</sup> O médico alemão Franz Joseph Gall (1758-1928) é considerado o fundador da frenologia. Lombroso foi o mais proeminente defensor dessa escola, publicando *L'Uomo Delinquente* em 1876 (Paul & Moore, 2010).

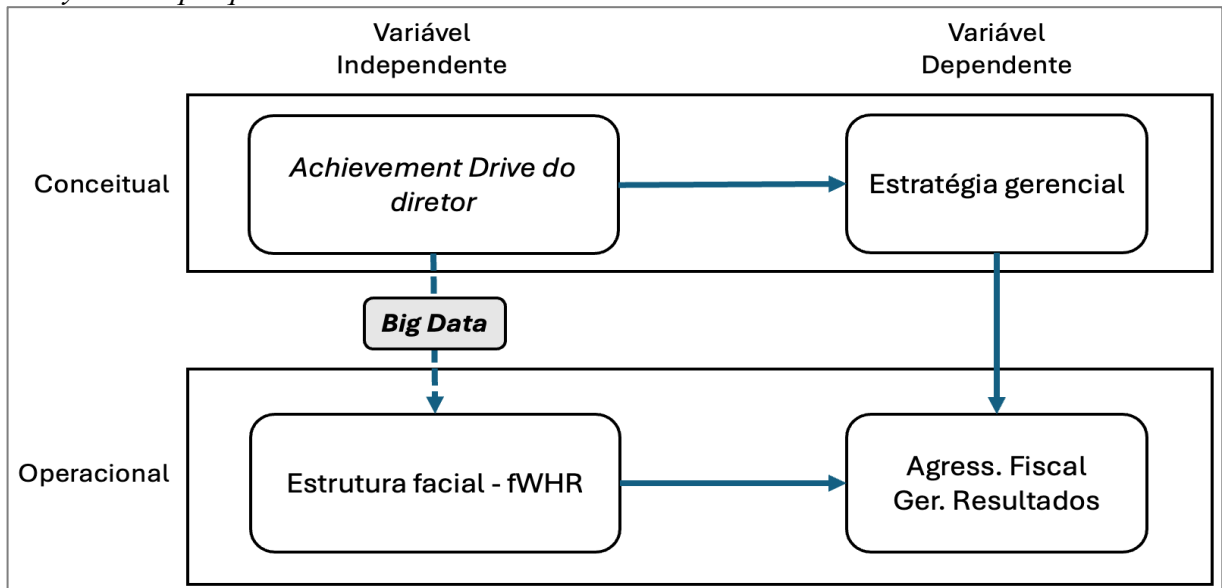
quando se busca capturar a complexidade dos fenômenos multivariados presentes nas decisões de gestores. A partir dessa lacuna, a utilização de big data e de indicadores biométricos como a fWHR emerge como uma alternativa metodológica promissora, ampliando a capacidade de análise de comportamentos estratégicos em ambientes corporativos.

O advento do big data representa uma transformação no campo contábil, tanto na prática quanto na pesquisa, ao fornecer ferramentas para analisar aspectos comportamentais de forma mais precisa e integrada. A incorporação de dados não financeiros — como imagens, textos, vídeos e áudios — possibilita uma compreensão mais completa do comportamento organizacional, oferecendo uma abordagem holística que integra aspectos subjetivos e objetivos nas decisões empresariais.

Nesta pesquisa, o termo big data é utilizado de forma abrangente, incluindo não apenas seu conceito e características tradicionais, mas também as tecnologias avançadas de ciência de dados, como a inteligência artificial, que permitem a extração de padrões e análise preditiva em grandes volumes de dados não estruturados. Considerada uma revolução comportamental, essa tecnologia reflete o compartilhamento contínuo e voluntário de dados pessoais e corporativos em escala global. No contexto empresarial, muitas companhias divulgam imagens de seus CEOs e diretores em sites oficiais e plataformas financeiras, criando uma base de dados acessível para análise. Neste estudo, o big data é empregado como uma ferramenta essencial para acessar, processar e interpretar dados visuais, aplicando técnicas de inteligência artificial que extraem informações biométricas e comportamentais dos líderes empresariais. Essa abordagem permite validar teorias comportamentais de forma empírica e em larga escala, aproveitando o compartilhamento voluntário de dados e a infraestrutura de dados em nuvem.

O principal construto que guia este trabalho é o *achievement drive*, que se refere à motivação intrínseca de indivíduos em alcançar metas e superar desafios (Carvalho & Conde, 2024); e será operacionalizado pela fWHR, um biomarcador que mede a razão entre a largura e a altura facial (He et al., 2019). Esse processo é viabilizado por algoritmos de visão computacional, que identificam e analisam traços faciais por imagens, transformando dados visuais em variáveis quantitativas passíveis de estudo empírico.

A variável dependente refere-se às estratégias gerenciais adotadas pelos CEOs, como planejamento tributário e gerenciamento de resultados, estimadas por meio de indicadores contábeis e financeiros. A Figura 1 ilustra graficamente a relação entre as variáveis conceituais e operacionais, centralizando a análise nas contribuições do big data.

**Figura 1***Libby box da pesquisa*

Adaptado de Libby et al. (2002)

Os aspectos internos considerados nesta pesquisa derivam de fatores genéticos e psicológicos, estando enraizados nas interações entre a mente — como um órgão biológico — e suas manifestações comportamentais. O estudo desses fatores é explorado por disciplinas como a genética comportamental e a psicobiologia (Moore, 2015; Motoki & Sugiura, 2017), oferecendo uma fundamentação teórica robusta e interdisciplinar para a análise da relação entre traços físicos e decisões estratégicas.

As estratégias gerenciais agressivas se referem às decisões e ações estratégicas ou contábeis tomadas pelos gestores, caracterizadas pelo alto grau de risco e pela intenção de maximizar resultados financeiros ou operacionais a curto prazo, muitas vezes às custas da estabilidade ou legalidade a longo prazo. Essas estratégias podem envolver escolhas contábeis arriscadas que, embora estejam dentro dos limites legais, utilizam brechas ou flexibilidades nas normas contábeis para manipular os resultados financeiros, como o gerenciamento de lucros ou o planejamento tributário agressivo.

Essas práticas podem incluir o adiamento de despesas, a antecipação de receitas, ou a reclassificação de ativos e passivos para melhorar a aparência financeira da empresa, criando uma percepção de maior rentabilidade ou solvência do que a realidade. O limite dessas práticas reside na linha tênue entre a otimização contábil permitida por lei e a manipulação contábil que distorce a verdadeira performance da empresa. Embora essas estratégias possam ser legais, elas podem ter consequências significativas tanto para a empresa quanto para os acionistas, como perda de credibilidade, penalidades regulatórias ou problemas de liquidez no futuro.

A análise dessas estratégias em conexão com as características individuais dos decisores envolvidos tem se tornado um tema crescente na literatura contábil e financeira, motivando a seguinte questão: como o *achievement drive* influencia estratégias gerenciais agressivas, como o gerenciamento de resultados e o planejamento tributário agressivo?

Com esse questionamento como guia, o **objetivo geral desta tese é investigar as associações entre o *achievement drive* dos gestores, medida através de inteligência artificial, e as estratégias gerenciais agressivas adotadas.** Esse estudo busca não apenas enriquecer o entendimento sobre os traços comportamentais que influenciam decisões gerenciais arriscadas, mas também fornecer uma base metodológica robusta que expanda o uso de novas tecnologias na pesquisa contábil e comportamental.

Dada essa associação, postulamos que a fWHR medida por visão computacional, em conjunto com dados financeiros, pode prever o envolvimento de executivos em práticas contábeis agressivas. Esta hipótese norteia a investigação empírica dos artigos subsequentes, com os seguintes objetivos específicos:

- I. Promover reflexão acerca dos riscos, desafios e oportunidades do uso de big data, sob a perspectiva do dualismo entre objetividade e subjetividade dos fatores que influenciam os usuários da contabilidade;
- II. Verificar se o planejamento tributário é influenciado pelo *achievement drive* do executivo, refletido em sua fWHR, coletada por visão computacional;
- III. Verificar se o gerenciamento de resultados é influenciado pelo *achievement drive* do executivo, refletido em sua fWHR, coletada por visão computacional.

O estudo se justifica pela relevância de compreender melhor as motivações que guiam as estratégias agressivas de gestores e as implicações que isso traz para a governança corporativa. Como já demonstrado na literatura, traços físicos podem estar associados a características como dominância e competitividade (Mazur & Booth, 1998), resiliência emocional (Amanatkar et al., 2014), e apetite por risco (Sapienza et al., 2009). Esse entendimento é essencial para ampliar a compreensão sobre a influência biológica e comportamental nas decisões organizacionais.

Os estudos de Kachur et al. (2020) e Naqvi et al. (2021) evidenciam que traços faciais e morfológicos possuem um impacto relevante na interpretação de comportamentos e personalidades, corroborando a relevância deste tema na academia. O primeiro estudo usou redes neurais artificiais para prever traços da personalidade com base em imagens faciais, enquanto o segundo identificou loci genéticos que afetam simultaneamente a forma do cérebro

e do rosto, sugerindo uma correlação genética entre morfologia facial e características cognitivas.

A aplicação prática deste estudo para os *stakeholders* reside na sua capacidade de fornecer uma ferramenta analítica que permita avaliar o comportamento de risco de CEOs e sua correlação com decisões contábeis agressivas. A estrutura facial mensurada pela fWHR pode atuar como um biomarcador que, analisado em conjunto com variáveis contábeis, possibilita inferências sobre a propensão dos executivos a adotar práticas que maximizem resultados a curto prazo, mesmo que envolvam maior risco ou agressividade contábil.

A tese está estruturada em três artigos: o primeiro abordará as pesquisas em contabilidade comportamental e os avanços proporcionados pelas tecnologias de big data. O segundo e terceiro artigos testarão empiricamente a relação entre fWHR e agressividade nas estratégias gerenciais, fornecendo novas evidências para a literatura sobre como fatores individuais influenciam as decisões corporativas.



## 2 CONTABILIDADE COMPORTAMENTAL NA ERA DO BIG DATA: UM ESTUDO TEÓRICO

### 2.1 Introdução

A prática contábil é um conjunto de atividades cujos efeitos influenciam diferentes grupos e indivíduos, provocando reações comportamentais diversas, sendo algumas delas observáveis. Uma vez que o fornecimento de informações relevantes à tomada de decisão é o objetivo principal da contabilidade, os efeitos comportamentais resultantes das informações, previsíveis ou não, são o objeto de estudo da contabilidade comportamental.

Os estudos comportamentais em contabilidade, cujo início é atribuído aos trabalhos de Argyris na década de 1950, expandiram-se durante os anos 60 e 70 quando os pesquisadores passaram a utilizar métodos e abordagens das ciências comportamentais para avaliar ações, decisões, julgamentos e respostas cognitivas às práticas contábeis. A contabilidade comportamental surge, então, como um ramo da contabilidade que analisa a conduta das pessoas quando se deparam com os fenômenos contábeis, tanto como o comportamento influencia, quanto como ele é influenciado por tais fenômenos. Seu objetivo é explicar essa influência, enfatizando a relevância da informação contábil no processo decisório, bem como o comportamento individual/coletivo motivado pela comunicação dessa informação (Belkaoui, 1989; Siegel & Ramanauskas-Marconi, 1989).

Predominando inicialmente experimentos que testavam teorias da psicologia, os procedimentos metodológicos evoluíram para além do laboratório, contando com uma pluralidade de técnicas como entrevistas, estudos de caso, questionários, dentre outras. Tal evolução compreendeu também o uso de teorias de outros campos de conhecimento, dando mais atenção à sociologia e incorporando achados recentes da psicobiologia e da neurociência cognitiva.

Com a especialização das ciências humanas, torna-se natural o surgimento de tópicos e campos de estudo comuns nessas diferentes ciências. Embora o crescimento dessa interdisciplinaridade seja proveitoso para geração de conhecimento diante da complexidade do ser humano, o uso diversificado de teorias oriundas da psicologia, da economia e da sociologia motivou diversas críticas durante a década de 70 que serviram de base para o estudo seminal de Colville (1981). O autor, ao sugerir uma “reconstrução da contabilidade comportamental”, defende a necessidade de se aplicar abordagens alternativas à que vinha sendo utilizada nessas pesquisas como condição essencial para que o campo se desenvolvesse.

Nessa mesma década, desenvolveram-se, nos estudos organizacionais, os debates objetividade-subjetividade e ação-estrutura. A metodologia do positivismo é contestada e a

pesquisa etnográfica passa a ser utilizada em pesquisas organizacionais. A etnografia, junto com a fenomenologia, o simbolismo, o cognitivismo, dentre outros instrumentos, constituíram o desenvolvimento da perspectiva subjetiva. Essa visão destaca que o mundo externo não possui sentido por si só, mas seu sentido é atribuído pelos processos cognitivos dos indivíduos, e esses processos devem ser objeto de estudo (Linstead, 1997; Peci, 2003).

Enquanto a objetividade predomina na análise macro organizacional, a subjetividade é mais forte nas análises em nível micro. No entendimento de Major (2008, p. 45), “a investigação positivista tem sido bem-sucedida na predição do comportamento econômico a nível agregado, mas foi confrontada com dificuldades na predição do comportamento individual”. A autora destaca que, devido à incapacidade do paradigma positivista de explicar as razões de um comportamento individual, diversos pesquisadores contestaram a relevância das pesquisas em contabilidade nas últimas três décadas.

Apesar das contestações, a teoria positiva permanece dominante nas pesquisas comportamentais em contabilidade, dada a sua capacidade descritiva e preditiva e o advento do fenômeno big data. Segundo Sætra (2018), o big data pode ser descrito como uma estrutura positivista, claramente empirista, pela qual os fatos observáveis são a única fonte reconhecida de conhecimento. Para o autor, as teorias psicológicas relacionadas à motivação, preferências e ações permanecem úteis para explicar o que se passa na mente humana, porém não seriam mais necessárias para prever práticas comportamentais quando se usa big data.

O desafio apresenta-se, portanto, em como examinar aspectos subjetivos sob a ótica positivista. Buscando contribuir para essa discussão, o objetivo deste estudo é promover reflexão acerca dos riscos, desafios e oportunidades do big data sob a perspectiva do dualismo entre objetividade e subjetividade dos fatores que influenciam o comportamento de usuários da contabilidade.

O trabalho contribui para o debate sobre o uso de procedimentos metodológicos alternativos ou complementares por meio do big data que, se aplicados de forma adequada, podem ser conciliados, proporcionando análises interdisciplinares mais abrangentes das reações comportamentais ao processo contábil. O estudo oferece elementos para discussão da importância de se promover uma cultura de big data, e que ela não se restrinja a áreas específicas da prática contábil, mas seja incorporada também na área acadêmica, aumentando a independência e a eficiência dos investigadores em contabilidade. Assim como as empresas utilizam ciência de dados para interpretar o comportamento do consumidor buscando conhecê-lo melhor para prever suas possíveis ações, o pesquisador pode aplicar as mesmas técnicas para

entender mais profundamente o comportamento do usuário da contabilidade, seja o preparador da informação contábil ou o que a consome para tomada de decisão.

## **2.2 Da primeira infância à busca pela identidade**

As pesquisas em contabilidade comportamental têm início com os estudos de Argyris (1952; 1953) abordando o comportamento das pessoas diante dos processos orçamentários e dos sistemas de controle. Nas décadas de 60 e 70 pesquisadores acrescentaram outro subconjunto ao campo, passando a focar fortemente em vieses comportamentais nas tomadas de decisões, que eram encaradas, antes das ciências comportamentais, como julgamentos baseados em fatos ou razões, isto é, em pressupostos da racionalidade. A Contabilidade Comportamental questiona isso, considerando que, mesmo diante de dados factuais, o julgamento pode resultar em escolhas diferentes das esperadas, explorando teorias com bases psicológicas que buscam explicar esses vieses (Hoque & Mai, 2018; Major, 2008).

Para descrever como se encontrava a literatura em contabilidade comportamental, Colville (1981) estabelece uma comparação com a primeira infância do desenvolvimento humano, caracterizada pela entrada da criança no mundo como uma confusão vibrante, mas que com o tempo começa a se estruturar, indo do caos a uma identidade. O autor defende que à época o campo parecia ainda estar lutando com sua própria infância, pois não havia conseguido se desenvolver em um corpo de conhecimento teórico ou prático coerente. Essa falta de coerência foi atribuída por Hofstede (1976) à diversidade de métodos e paradigmas utilizados que fizeram a contabilidade comportamental perder o foco, tornando-a inútil. Para Colville, a incoerência seria resultante em parte do alinhamento das ciências comportamentais com a abordagem científica natural, em que predominavam os estudos com foco na análise da resposta comportamental após estímulo, além de haver uma grande preocupação com a generalização dos achados.

Colville (1981) destaca outros autores que à época puseram em dúvida o mérito e o futuro da contabilidade comportamental. O autor discute, dentre outras, as avaliações (ambas publicadas em 1973) de Birnberg, que afirmou que a área não prometia muito para o futuro, e de Green, que sugeriu tratar-se de uma moda que passaria rapidamente. Para Colville (1981), essas críticas poderiam gerar conclusões precipitadas, pois havia pontos a serem explorados que formariam a base para a reconstrução do campo por meio de abordagens alternativas. Ele sustenta seus argumentos na perspectiva weberiana, pela qual o mundo social não pode ser entendido da mesma maneira que o natural, pois os interesses cognitivos que orientam o

conhecimento são distintos. Enquanto as ciências naturais se interessam pelo que é geral e repetitivo, as sociais buscam aquilo que é único ou singular.

Essa perspectiva difere da de Durkheim, em que o fato social é tratado como coisa, com pressupostos similares aos das ciências naturais, separando o sujeito do objeto (Durkheim, 2007). O procedimento adequado é não isolar o sujeito, considerando que a ação social é construída coletivamente na intersubjetividade. Enquanto Durkheim foca no fato social, Weber foca no indivíduo, e sem indivíduos não há fato social e, por conseguinte, não há fenômeno gerado pela interação. A concepção de Weber vai além da simples identificação de padrões, contribuindo para a compreensão profunda do comportamento. Assim, para que haja um enriquecimento da contabilidade comportamental e desenvolvimento de uma estrutura prática e teórica coerente, os estudos deveriam abordar o ser humano como ser social em um processo intersubjetivo que possibilitasse a identificação dos significados, indo além da realidade identificada com base no estímulo/resposta (Colville, 1981).

Birnberg, que em 1973 avaliara que a contabilidade comportamental não prometia muito para o futuro, faz uma nova avaliação em 2011 sobre o campo. No entendimento do autor, a literatura do campo evoluiu em amplitude, profundidade e complexidade, levando a uma indefinição de seus limites, devido à diversidade dos métodos e teorias utilizadas. O interesse ampliou-se de maneira que tópicos das finanças e da contabilidade que não seriam considerados parte da contabilidade comportamental têm claramente focado no entendimento do comportamento de investidores e de outros usuários (Birnberg, 2011).

Esse crescente interesse motivou a fundação de periódicos dedicados exclusivamente à contabilidade comportamental, como o BRIA – *Behavioral Research In Accounting* – em 1989, e o *Advances in Accounting Behavioral Research*, que já se encontra em seu 26º volume. Nas revisões de Meyer e Rigsby (2001) e de Kutluk e Ersoy (2010) dos trabalhos publicados no BRIA, compreendendo, respectivamente, os dez primeiros anos da revista, e os dez anos seguintes, nota-se uma predominância da utilização de experimentos, e em segundo lugar a aplicação de questionários como procedimentos metodológicos.

### **2.3 A busca pelos fatores subjetivos que interferem no comportamento**

A concepção objetiva é retratada na literatura contábil em pesquisas envolvendo, entre outros, o tema manipulação de resultados. As abordagens evoluíram a partir de modelos empíricos publicados nas décadas de 80 e de 90, como o de Healy (1985) e o de Jones (1991), tornando-se um dos tópicos mais frequentes no paradigma positivista em contabilidade. Desenvolveu-se um corpo teórico com base nesses conceitos, em que diferentes padrões de

comportamento foram analisados e testados pelo método hipotético-dedutivo, predominando a perspectiva da estrutura em que se considera um elemento motivador para estimular a reação do usuário ou do preparador da informação contábil.

Utilizando tradicionalmente um fato ou evento motivador para a manipulação do componente discricionário do resultado contábil, esses estudos buscam, em uma visão objetiva, encontrar padrões comportamentais, enfatizados pela significância estatística e possibilidade de generalização. Ao isolar o comportamento predominante diante do evento ou oportunidade que estimula a manipulação, a visão objetiva ignora os aspectos subjetivos do agente, seus valores, princípios e emoções. Sob a ótica dos métodos quantitativos, esse fator subjetivo não observável estaria no termo de erro, não considerado nas variáveis relevantes do modelo estatístico. A visão subjetiva aplicada nesses estudos pode complementar esse corpo teórico, à medida em que permite a análise do elemento “desmotivador”, interno ao indivíduo ou ao grupo, que moderaria a influência do elemento motivador.

Os estudos comportamentais com metodologias orientadas à análise estímulo-resposta podem ser divididos em duas perspectivas. Na primeira, há o foco na perspectiva macro ou holista, em que o estímulo testado vem do ambiente, muitas vezes representado por uma variável dicotômica – se exposto ao estímulo ou não – que testa grupos de empresas ou períodos distintos. Na segunda, existe o foco nos fatores internos do indivíduo que impactarão na resposta. Nesta última, o estímulo não é mensurado como na primeira perspectiva, que é claramente observado sem uma aproximação do pesquisador e representado por uma variável categórica de forma objetiva.

Com o fim de superar a dicotomia individualismo/holismo e estrutura/agente, investigadores em contabilidade comportamental buscam uma aproximação dos indivíduos por meio de questionários ou experimentos em laboratórios, pelos quais os participantes do estudo podem classificar estímulos internos relacionados a sentimentos, valores ou características da personalidade.

O estudo de Murphy et al. (2020), ao explorar os fatores internos e externos que estimulam a honestidade, mostra em seus achados um aspecto que reflete o comportamento resultante da interação estrutura/agente, imperceptível em uma análise isolada. Os autores se basearam na teoria da autodeterminação proposta por Ryan e Deci (2000) e encontraram que pessoas possuidoras de motivações internas superiores para relatar honestamente podem se rebelar contra um controle percebido como ameaçador.

Esses estudos apoiam que a tomada de decisão não é influenciada apenas por elementos motivadores do ambiente, mas também por características individuais do responsável que

interagem com esses elementos. A investigação que considera somente a estrutura e os elementos motivacionais impostos por ela é severamente objetiva, e não captura a interação da estrutura com o agente, que possui desejos e livre arbítrio, podendo agir de forma diferente do padrão natural. Na análise pela concepção objetivista, os dados são mais facilmente observados e coletados, enquanto uma análise que foca somente no agente considera o subjetivo em detrimento da influência da estrutura.

No uso de experimentos em laboratório, estudos já demonstraram que o agente se comporta de forma diferente quando a pessoa com quem ele interage está presente no lugar da simulação, fato considerado como uma armadilha do experimento psicológico (Blascovich et al., 2002; Sternam & Zibrek, 2021). Essa interação estaria dentro de uma combinação de objetividade e subjetividade não excludentes, mas complementares. Quando usada adequadamente, essa combinação promove enriquecimento da literatura em contabilidade comportamental.

Os experimentos em que se isola o participante dominam a psicologia, entretanto é importante lembrar que essa disciplina se concentra exclusivamente no comportamento humano. O foco no agente corresponde a estudar o impacto do comportamento do indivíduo ou do grupo no sistema contábil. Esse enfoque contribui para a análise tanto da característica comportamental individual quanto da prática social produzida a partir das interações coletivas e de que forma o processo contábil é impactado.

## **2.4 Indo além das teorias psicológicas e sociológicas**

Um tópico significativo na literatura de contabilidade e de finanças comportamentais é o estudo de comportamentos de investidores e gestores que afetam decisões envolvendo risco econômico. Os trabalhos de cientistas de outros campos como os psicólogos Kahneman e Tversky na década de 1970, e Simon na década de 1950, que pesquisava em áreas diversas, motivaram as pesquisas em economia a não considerarem as decisões puramente racionais, mas incluírem questões não econômicas, internas do decisor, como seu inconsciente e suas emoções (Kapoor & Prosad, 2017).

Diante da busca pelas dimensões não econômicas, novos métodos têm sido utilizados para pesquisar questões antigas nas ciências comportamentais com foco em práticas contábeis. Rose et al. (2022) mediram o nível de euforia de auditores por meio de experimentos em laboratório com base em rastreamento ocular e pupilometria. O estudo possibilitou identificar como diferentes estímulos externos provocam respostas psicofisiológicas das pessoas.

Crescem também as pesquisas com o apoio de áreas emergentes como a neuroeconomia, permitindo aos pesquisadores adentrarem na atividade cerebral durante a tomada de decisões. Em parcerias com neurocientistas, investigadores em contabilidade buscam descobrir o que estaria por trás do comportamento observado. A abordagem estímulo/resposta é invertida nesse caso, já que o comportamento que é normalmente analisado como resposta passa a ser o fator que estimula a atividade do centro do cérebro (Birnberg, 2011).

Nessa mesma linha de pesquisa há estudos que relacionam a resposta cerebral a determinados hormônios, concluindo que existe uma base genética que interfere nos níveis hormonais, e estes se associam a padrões distintos de conduta (Kuhnen & Chiao, 2009; Zak, 2018). Pesquisas na área têm revelado mecanismos biológicos que suportam os aspectos que podem caracterizar diferenças individuais no que concerne à assunção de risco e nível de agressividade que interferem na tomada de decisão. Tais diferenças são influenciadas por fatores biológicos ou ambientais que caracterizam práticas comportamentais e a personalidade de um indivíduo.

De acordo com o behaviorismo, a personalidade é o resultado da soma de respostas aprendidas ou hábitos desenvolvidos ao longo da vida. Essa visão mecanicista dos indivíduos é defendida pela escola de psicologia fundada por John Watson, e valoriza especialmente os estímulos externos como fatores determinantes da personalidade (Schultz & Schultz, 2016).

A abordagem de traços, por sua vez, defende que a personalidade está diretamente relacionada à herança genética dos seres humanos, a qual representa um componente significativo da personalidade. Essa abordagem ganhou espaço na psicologia científica a partir dos estudos de Gordon Allport e Raymond Cattell. Em 1937, Allport publicou *Personality: A Psychological Interpretation*, e seguiu por quase quatro décadas pesquisando o papel dos traços na psicologia da personalidade e na psicologia social. Seus estudos se deram no ambiente acadêmico de Harvard, e apresentaram como diferencial a observação de pessoas emocionalmente saudáveis, afastando uma abordagem exclusivamente psicoterapêutica, que utiliza casos específicos ou entrevistas com pacientes previamente identificados com algum distúrbio emocional. Como resultado, o autor apresentou uma visão interativa do comportamento, demonstrando-o como resultante do relacionamento entre os traços pessoais e o ambiente em que os indivíduos vivem (Schultz & Schultz, 2016).

Schultz e Schultz (2016) acrescentam ainda que, apesar de reconhecer a importância desta interação, Allport defende que a singularidade dos seres humanos é definida, principalmente, pela sua carga genética, que fornece a matéria prima da personalidade. A infinidade de combinações genéticas possíveis ajudaria a compreender, portanto, porque dois

indivíduos (irmãos, por exemplo), quando submetidos a influências externas semelhantes, apresentam personalidades distintas. O psicólogo alemão Hans Eysenck, outro teórico dos traços, também comprovou a influência dos traços na extroversão, neuroticismo e psicoticismo. Para esse autor, a personalidade de um indivíduo é descrita suficientemente por esses três fatores (Cooper, 2010). Em complemento à teoria de Eysenck, Costa e McCrae (1988; 1992) acrescentaram à extroversão e ao neuroticismo a abertura à experiência, a socialização e a realização dos indivíduos, propondo um modelo de personalidade associado a cinco fatores com base biológica (*five-factor model*).

Estudos que exploram a genética comportamental, ao analisarem diferenças individuais em gêmeos indicam que fatores genéticos explicariam entre quarenta e sessenta por cento da variação em traços de personalidade (Bratko & Butkovic, 2007; Brody, 1997; Stelmack, 1997). Independente das porcentagens encontradas, existem evidências crescentes de concordância na literatura de uma visão interacionista, pela qual a personalidade é moldada por fatores internos (genéticos) e externos (ambiente). Assim, herdamos disposições e tendências, mas as certezas só serão confirmadas nas condições sociais e ambientais vividas (Plomin et al., 1990).

No que tange aos fatores genéticos, segundo Sisk et al. (2013), a exposição à testosterona interfere na organização das redes neurais, o que permite relacionar a exposição hormonal a comportamentos que envolvem agressividade e propensão ao risco. Pesquisas em genética comportamental defendem que regiões cerebrais como lobos frontais, a amígdala e o hipocampo são influenciados por essa exposição e isso tem importância fundamental em perfis de agressividade (Figueredo, et al., 2006; Sisk & Foster, 2004).

O nível de testosterona interfere na atitude do decisor em relação ao risco, se neutro, avesso ou amante do risco. Dessa forma, é possível enriquecer as análises de um fator subjetivo, como a agressividade e assunção ao risco, com uma proxy objetiva: o nível de testosterona. No entanto, medi-lo envolve altos custos para a pesquisa, já que são necessários, a princípio, exames laboratoriais, nos quais é medido o número de nanogramas por decilitro de sangue. Além disso, o nível do hormônio flutua durante o dia, de acordo com costumes alimentares, sono e atividades físicas, dificultando ainda mais o uso dessa proxy. Um período de exposição à testosterona pode ser transitório ou permanente, que gera os chamados efeitos organizacionais. Os efeitos dessa flutuação relacionada aos níveis transitórios da testosterona são classificados como ativacionais. Os estudos que analisam sua influência na propensão ao risco e agressividade consideram os efeitos organizacionais, que são as mudanças que a testosterona provoca no desenvolvimento individual em sua fase pré-natal e na puberal (Archer, 2006; Arnold & Breedlove, 1985; Liao et al., 2021; Mazur & Booth, 1998)



De acordo com Sisk et al. (2013), tais mudanças persistem após o fim da adolescência, em que ocorre a exposição ao hormônio e gera predisposições a atitudes específicas. Os mesmos autores sustentam que a exposição durante a fase puberal impacta também em aspectos físicos, como a estrutura facial do indivíduo. Diante disso, estudos em ciências comportamentais tem utilizado biomarcadores como proxy para o nível de testosterona do indivíduo, considerando-o como importante fator que caracteriza seu perfil.

As pesquisas que utilizam características físicas consideram seus achados uma importante contribuição para a literatura, ao fornecerem uma nova forma de análise preditiva com base em dados facilmente observados, mas que representariam características da personalidade do indivíduo, não observáveis para o observador externo. Assim, recentes estudos na literatura contábil valem-se da psicobiologia para associarem o nível da testosterona a características físicas como a estrutura do rosto, observáveis até por fotos, sem a necessidade de exames laboratoriais (Chan & Wang, 2021; He et al., 2019; Jia et al., 2014).

A interdisciplinaridade com ciências de campos fortemente distintos parece ser um dos fatores que mais favorecem o desenvolvimento e ampliação do interesse nas ciências comportamentais. Inicialmente a construção de conhecimento se desenvolvia pela solidariedade por semelhanças, como a evolução da contabilidade com apoio da economia e da administração. Atualmente, as ciências se desenvolvem em uma interdependência por heterogeneidade, funcionando organicamente para explicarem fenômenos complexos, como os estudos citados em que interagem genética e contabilidade. Esses estudos, embora apliquem integralmente a ótica objetivista em sua metodologia, refletem uma busca da academia em complementar as análises comportamentais com proxies que representam o caráter subjetivo do agente, relacionado à sua personalidade, que seria formada, de acordo com teorias psicológicas, por fatores ambientais e hereditários.

## **2.5 Big data e seus efeitos na pesquisa comportamental**

O desenvolvimento tecnológico da gestão da informação pode ser um dos principais fatores que tem motivado a predominância do paradigma positivista nas pesquisas comportamentais. A crescente capacidade tecnológica de otimizar os recursos necessários para coleta e análise de grandes bases de dados, por exemplo, tem permitido a inclusão de um número cada vez maior de indivíduos em um estudo. Além disso, essa mesma evolução tecnológica, aliada à propagação da internet, promove um maior armazenamento e divulgação de dados pessoais, permitindo aos algoritmos coletarem informações que podem ser usadas como proxies para mensuração de características subjetivas do agente que influenciam na

reação comportamental. Dentre elas, são consideradas o humor, desejos, percepções, além de um histórico do indivíduo que contribui para uma caracterização do ambiente de formação de sua personalidade.

Nesse diapasão, as plataformas virtuais tornaram-se um ambiente onde os agentes interagem de maneiras específicas, podendo refletir nas redes sociais características reais ou simuladas pelos indivíduos. Essa dualidade de comportamento exige um nível de rigor diferente da coleta de dados face a face, de modo a se evitarem vulnerabilidades como distorções passíveis de ocorrerem em *surveys* distribuídos pela web, por exemplo.

Nesta seção, esse e outros desafios do big data serão discutidos à luz de suas características, bem como as oportunidades que esse fenômeno tem oferecido para as pesquisas comportamentais.

### **2.5.1 Características do big data**

O big data é definido de diversas formas na literatura. Embora carente de clareza ontológica, as definições direcionam não para o que é, mas para um conjunto de características-chave, como: grande volume, alta velocidade de dados gerados continuamente, alta diversidade quanto à natureza, flexibilidade, escalabilidade, dentre outras (Boyd & Crawford, 2012; Zhang et al., 2015).

Os dados que caracterizam o comportamento humano podem ser gerados de forma direcionada, automatizada ou voluntária. Como exemplo de forma direcionada, tem-se os dados extraídos de tecnologias de vigilância, que podem focar em um indivíduo ou grupo. Já a forma automatizada compreende os registros de dispositivos ou softwares que armazenam cada ação e interação da pessoa, como histórico de navegação em sites, uso de meios de transporte por cartões digitais, passaportes, registros de pagamento e inúmeras outras possibilidades que vem surgindo a cada dia pela “Internet das coisas”. Finalmente, os dados voluntários consistem principalmente naqueles fornecidos pelo usuário, como a interação em redes sociais (Kitchin, 2013).

O efeito do big data na contabilidade aumenta à medida em que os registros contábeis, historicamente físicos, têm se tornado cada vez mais digitalizados (Warren et al., 2015). Além da abundância de dados gerada muitas vezes em tempo real por essas diferentes formas, a facilidade crescente de acesso e de análise, e o custo decrescente promovem novas oportunidades para as pesquisas comportamentais, mas também riscos e desafios.

### 2.5.2 *Riscos, desafios e oportunidades*

Um dos principais riscos assumidos no uso de big data diz respeito à qualidade dos dados, diante da falta de garantia de que todos os dados são confiáveis. A diversidade de abordagens e de infraestruturas entre as bases consiste em um grande desafio no que concerne à padronização de critérios utilizados para considerar a utilidade dos dados como fonte de conhecimento. Além disso, os pesquisadores, ou quem reinterpreta os dados produzidos por outra fonte, podem divergir quanto a critérios de avaliação da qualidade dos dados (Leonelli, 2017). No entanto, o poder que o big data possui de examinar em conjunto dados de naturezas diversificadas pode auxiliar na redução desse risco por meio da triangulação, em que diferentes fontes podem confirmar o que foi interpretado, aumentando a confiabilidade dos dados.

A incerteza quanto à qualidade dos dados se deve especialmente à confiabilidade das fontes e à sua complexidade. Essa qualidade deve ser avaliada quanto à atualidade, veracidade e integralidade, uma vez que, mesmo sendo reais, eles podem ser parciais, fornecendo informações seletivas da realidade. Ou ainda, informarem algo real, porém em sentido inverso ao desejado, como nos casos em que os indivíduos se expressam a partir do uso de ironias.

Considerando os avanços computacionais de armazenamento e análise de grandes volumes de textos de forma automatizada, os algoritmos de mineração de textos exercem um papel fundamental na identificação de padrões que podem ser úteis para a predição e interpretação de comportamentos. Aplicados com técnicas de IA – inteligência artificial, esses algoritmos possibilitam a identificação de ironia, sarcasmo e figuras de linguagem (Cambria & White, 2014). Embora possam não estar presentes em relatórios de gestão, esses elementos são frequentemente utilizados em e-mails, páginas da web, redes sociais e mídias de notícias, podendo distorcer o processo de identificação de padrões se não forem corretamente interpretados.

Os dados textuais das comunicações empresariais possuem alto valor informativo para os estudos comportamentais. Fenômeno crescente no marketing empresarial, a mídia social é uma das maiores e mais rápidas coleções de dados relevantes (Warren, Moffitt, & Byrnes, 2015). À medida em que se combinem dados financeiros tradicionais com textos publicados nas mídias, pode-se estudar tendências comportamentais como, por exemplo, as reações dos investidores após uma declaração dos CEOs, os quais, segundo Kelton e Pennington (2020), estão utilizando cada vez mais as redes sociais para divulgarem informações e se comunicarem com a sociedade.

Na estrutura do big data, dados coletados de quaisquer formas, estruturados ou não, representam fatos observáveis que podem ser submetidos a técnicas de IA e de aprendizado de máquina, pelas quais são gerados conhecimentos mediante raciocínio e lógica (Sætra, 2018). Tais técnicas emulam a interpretação humana dos dados por meio de algoritmos computacionais.

Utilizando IA aplicada à análise de sentimentos, os estudos de Galdi e Gonçalves (2018) e de Tetlock et al. (2008) examinaram grandes conjuntos de edições diárias de jornais para verificar se há reações distintas dos investidores diante de uma linguagem otimista ou pessimista. A análise de sentimentos consiste na aplicação de técnicas de processamento de linguagem natural com o fim de identificar e extrair informações subjetivas de textos (Argawal et al., 2015).

As técnicas de IA auxiliam na identificação do conteúdo não verbal, que pode ser mais valioso e relevante para a pesquisa do que o que foi efetivamente escrito. Para simularem as habilidades humanas, elas têm sido desenvolvidas em outras aplicações além de textos, como áudios, vídeos e fotos.

Por meio de análise textual e reconhecimento da expressão facial combinando técnicas de IA, Choudhury et al. (2019) desenvolveram um método de codificação de dados textuais não estruturados a partir de dados de áudio e vídeo para classificar estilos de comunicação em entrevistas em vídeo de CEOs de 69 organizações. As entrevistas possuíam entre 1,5 e 2 horas de duração e, com algoritmos de IA que interpretam dados de imagens, os autores conseguiram identificar as expressões dos entrevistados (se sérias, empolgadas, desligadas, melancólicas ou dramáticas) e relacioná-las com as transcrições dos áudios. De acordo com a pesquisa, os achados contribuem para a previsão de mudanças estratégicas da empresa, com base em traços comportamentais do CEO.

Combinar campos distintos como genética, psicologia e contabilidade tem sido outra oportunidade de pesquisa estimulada pelo processamento de imagens. Como tratado em seção anterior deste estudo, uma das formas de se analisar as disposições moldadas por fatores biológicos tem sido a utilização da estrutura facial como proxy para prever características comportamentais relacionadas a níveis altos de testosterona no homem.

Diante da dificuldade em se medir o nível de testosterona de cada indivíduo a ser analisado, a utilização da estrutura facial permitiu ampliar as amostras das pesquisas, uma vez que ela pode ser determinada a partir de uma foto, pela qual se mede a relação largura/altura da face. A essa relação dá-se o nome fWHR (*facial width-to-height ratio*). Pesquisas como as de Haselhuhn e Wong (2012) e de Jia et al. (2014) têm encontrado relações significantes entre

valores maiores de fWHR e aspectos negativos como fraudes, comportamentos antiéticos e declarações financeiras incorretas. Já Geniole et al. (2014) relacionaram alta fWHR à disposição de enganar e explorar a confiança de outros como estratégias utilizadas na busca por poder, status e ganho financeiro.

Esses estudos combinam teorias provenientes de diversos campos, sendo as fotos dos CEOs analisadas de forma parcialmente informatizada, em que o pesquisador precisa traçar linhas nas imagens digitais. Os algoritmos de IA conhecidos como visão computacional podem aumentar a eficiência da análise com um processo mais rápido e preciso na mineração de dados das imagens, além de evitar potenciais falhas de medição por interferência humana.

A visão computacional consiste em uma técnica que visa automatizar processos complexos que imitam a visão humana na identificação de padrões em imagens. Medindo a fWHR por meio dessa técnica, Kamiya et al. (2019) analisaram imagens faciais de 1.162 CEO's. Seus achados sugerem uma associação significativa entre maior fWHR e maior assunção ao risco. Segundo os autores, pela primeira vez na literatura, foi usada a inteligência artificial para medir a fWHR de forma automatizada, com o fim de evitar erros humanos na medição e encontrarem resultados consistentes na verificação de robustez.

No entanto, o uso dessas técnicas inovadoras não está isento de riscos. A aplicação de big data em análises comportamentais, ao mesmo tempo em que amplia as possibilidades de compreensão de padrões, também abre espaço para a exploração de sua dupla utilização. Essa ambiguidade surge no fato de que, dependendo do propósito, os dados podem ser usados tanto para aprimorar a tomada de decisões empresariais, quanto para sustentar práticas questionáveis, como manipulação de percepções ou reforço de estereótipos, prejudicando o ambiente organizacional. Dessa forma, o mesmo conjunto de dados que oferece insights valiosos sobre o comportamento dos CEOs pode, inadvertidamente, ser utilizado de maneira tendenciosa ou discriminatória, subvertendo o propósito original da análise.

Esse duplo potencial exige uma regulamentação mais rigorosa e uma supervisão contínua. O uso ético de big data deve garantir que os dados sejam aplicados de maneira justa, evitando interpretações enviesadas que possam resultar em práticas empresariais prejudiciais ou no reforço de preconceitos.

### ***2.5.3 Vantagens perante os métodos tradicionais***

Além do volume de dados, outra oportunidade oferecida pelo big data é a utilização de dados oportunos, detalhados e interrelacionados de fontes de diversas naturezas, que permitem uma compreensão mais profunda do comportamento humano. O foco nos fatores internos exige

uma aproximação do pesquisador, o qual necessita identificá-los em cada indivíduo, ampliando os custos da pesquisa e prejudicando a validação externa da hipótese testada. O big data possibilita que o pesquisador vá além de limitações dos métodos tradicionais como os custos relacionados às entrevistas, os riscos de distorções nas respostas dos questionários, e o isolamento do indivíduo de seu ambiente no caso da maioria dos experimentos.

Experimentos só são considerados apropriados, no entendimento de Birnberg (2011), quando são bem conhecidas as dimensões relevantes do ambiente em que o decisor interage com o estímulo. Esse método consiste na análise do comportamento do agente antes e depois de um estímulo, pelo qual os pesquisadores podem estudar tanto aspectos externos quanto internos do indivíduo. De acordo com Birnberg (2011) uma parte significativa da literatura em contabilidade concentrou-se a partir da década de 90 em experimentos com dimensões não econômicas, caracterizadas pelos aspectos internos e subjetivos ligados ao estado emocional do agente.

A contabilidade comportamental foca na influência que o comportamento causa no processo de tomada de decisão relacionada à prática contábil, e a conduta analisada é gerada individual ou coletivamente diante de uma estrutura que muitas vezes não pode ser simulada em laboratório. Para que a análise contemple essa interação, é necessário coletar, com o indivíduo em seu ambiente natural, um número suficiente de variáveis que possam caracterizar também os fatores internos que influenciam seu comportamento.

A complexidade inerente ao comportamento humano e as dificuldades enfrentadas na observação abrangente de suas múltiplas facetas evidenciam as limitações dos métodos experimentais tradicionais, os quais, ao dependerem de coleta de dados estruturados e condições controladas, podem resultar em análises enviesadas que não capturam adequadamente a dinâmica causal entre aspectos individuais e tomadas de decisão. Ademais, a prevalência de variáveis em forma de dados não estruturados representa um obstáculo adicional à coleta de informações por esses métodos convencionais.

#### ***2.5.4 Objetivando a subjetividade***


A relação entre big data e a tentativa de traduzir conceitos subjetivos em métricas objetivas pode ser comparada à construção de um poliedro inscrito em uma esfera, onde cada face representa uma variável mensurável. Nessa analogia, diferentes disciplinas científicas direcionam seu campo de visão para a esfera a partir de diferentes direções e ângulos. Estas visões interdisciplinares são essenciais, pois permitem a sobreposição e a integração de diferentes perspectivas, enriquecendo a compreensão do fenômeno. No entanto, mesmo com

visões interdisciplinares, há espaços que permanecem não preenchidos, representando dados perdidos ou não coletados objetivamente.

O uso adequado do big data tem o potencial de revolucionar a pesquisa científica ao aumentar significativamente o número de variáveis operacionais disponíveis para análise, permitindo uma aproximação mais precisa dos fenômenos complexos, da mesma forma como o aumento do número de faces do poliedro permite sua aproximação ao formato da esfera (Figura 2). Atributos subjetivos, muitas vezes não inseridos na pesquisa por limitações metodológicas, podem ser integrados ao processo de análise, complementando a visão objetiva e promovendo uma compreensão mais completa e multidimensional do comportamento humano.

**Figura 2**

*Poliedros inscritos em esfera*



As teorias de Lawrence (1997) sobre demografia organizacional ilustram essa complexidade ao abordar variáveis demográficas como substitutos de conceitos subjetivos, como atitudes e cognições. Esses conceitos são frequentemente negligenciados em pesquisas quantitativas, resultando em uma "caixa preta" teórica que obscurece os processos que efetivamente conduzem os resultados observados. O modelo de Lawrence propõe três interpretações distintas, onde a variável demográfica pode ser instrumental, indicadora ou mediadora de conceitos subjetivos. Essas interpretações sublinham a importância não apenas de capturar dados objetivos, mas também de compreender como essas variáveis se conectam com fatores subjacentes que realmente explicam o comportamento observado.

A epistemologia de big data, nesse contexto, não deve se limitar a previsões exatas e modelagens instrumentais. Tal como argumentado por Pfeffer (1983), existe uma tensão entre predição e explicação. Modelos preditivos podem ser eficazes para antecipar resultados, mas frequentemente falham em elucidar os processos pelos quais esses resultados são alcançados.

Um exemplo disso é o uso de dados demográficos de CEOs como preditores de risco, quando se observa uma correlação entre características faciais e comportamentais, mas sem explorar os mecanismos subjetivos que mediam essa relação. A abordagem epistemológica de Lawrence alerta para os perigos de simplificações excessivas, que podem negligenciar os processos internos que realmente guiam o comportamento.

Aplicar big data para transformar subjetividades em objetividades carrega o risco de eliminar nuances importantes na interpretação dos fenômenos. A visão relacional, por exemplo, sugere que variáveis demográficas podem funcionar como indicadores de processos internos, como motivações ou cognições, sem que esses processos sejam diretamente medidos. A tentativa de capturar todos os aspectos de um fenômeno complexo através de dados objetivos pode resultar em modelos que deixam de lado nuances essenciais, como ocorre quando variáveis demográficas são usadas como proxies para estados mentais.

Contudo, argumenta-se que a objetivação de variáveis subjetivas não precisa, necessariamente, comprometer o rigor científico. Na verdade, pode complementar a análise. Lawrence (1997) propõe que, ao invés de suprimir a subjetividade, devemos buscar formas de integrá-la de modo estruturado ao processo analítico. Big data oferece a possibilidade de coletar e analisar uma grande quantidade de dados que antes estavam fora do alcance da metodologia tradicional. Isso significa que, ao invés de eliminar a subjetividade, podemos objetivá-la e usá-la como um componente ativo no desenvolvimento de teorias mais robustas e fundamentadas.

## **2.6 Conclusões**

O presente estudo discutiu sobre a relação entre pesquisas em contabilidade comportamental e uso de técnicas de IA para análise de elementos de difícil observação, com base em teorias de outros campos de conhecimento como a psicobiologia. Esses elementos constituem dados subjetivos que exigem interpretação humana para que se extraiam informações úteis à pesquisa. Com algoritmos de IA, eles podem ser coletados e interpretados em grandes amostras sem isolar o indivíduo de seu ambiente natural.

A discussão considera que o pesquisador em contabilidade comportamental pode potencializar suas pesquisas à luz dessas técnicas. Para isso, é necessário compreender seu funcionamento, bem como seus riscos e seu estado atual, para que seus métodos acompanhem as céleres evoluções e mantenham um baixo custo computacional.

A contabilidade comportamental trata da relação de retroalimentação da contabilidade sobre o comportamento individual e agregado e deste sobre as práticas contábeis. Enquanto outras ciências estudam o elemento isolado, a contabilidade como ciência social aplicada deve



buscar a explicação para fenômenos que não existem no estudo isolado dos elementos. A contabilidade explica um fenômeno novo, criado no ambiente organizacional.

Mesmo que haja estímulos externos para práticas desonestas, como programas de bonificação para gestores ou ausência de ferramentas de controle, os gestores podem orientar sua conduta conforme seus estímulos internos, como seus valores, ou ainda agirem honestamente apenas com o objetivo de parecerem honestos como única motivação. Isto é, serem mais propensos a parecerem honestos do que honestos. O que seria mais importante para a contabilidade comportamental? Compreender essa complexidade, ou tentar descrever e prever sob que circunstâncias os gestores são propensos a serem desonestos?

Embora incapazes de explicar essa complexidade, as pesquisas positivistas são adequadas para descrição e previsão de comportamentos em nível agregado. No sentido de ampliar possibilidades de estudos, o big data permite combinar as contribuições do positivismo e seu poder de generalização com um alcance mais profundo na análise, por meio das dimensões internas do indivíduo, que condicionam sua reação ao estímulo do ambiente. O objeto de estudo da contabilidade comportamental resulta de uma interação entre os estímulos do ambiente e esses fatores internos, causados pelas especificidades históricas, sociais e genéticas. Utilizar essas especificidades pode ampliar o alcance da análise objetiva, no que tange à compreensão em nível micro e em que nível elas interferem no comportamento em um contexto relacionado à contabilidade. Assim, a reflexão feita aqui não implica em mudança de paradigma de pesquisa, mas ampliação da capacidade preditiva das pesquisas positivistas por meio do big data.

Ressaltamos, diante disso, a importância de se trabalhar com pressupostos das visões objetiva e subjetiva nos estudos comportamentais. O propósito é provocar uma reflexão sobre a importância de se compreender os dois hemisférios em conjunto focando no lado reflexivo do fenômeno, pelo qual a estrutura estimula um comportamento do agente que por sua reação é gerada uma contrarreação da estrutura. Teorias comportamentais próprias da contabilidade podem resultar da análise desse ciclo nessa forma conjunta.

Entretanto, destacamos o potencial do big data de identificar de forma objetiva aspectos tradicionalmente identificados apenas pela visão subjetiva. Comparamos a abordagem de se mapear essas nuances subjetivas inerentes ao indivíduo por entrevistas e experimentos laboratoriais à observação de uma esfera, na qual as vistas distintas são fluidas e sem contornos claros. Em contraste, a objetividade demandada pelo rigor científico positivista aspira à precisão de um poliedro, cujas faces e vértices definem claramente as diferentes perspectivas. A utilização do big data, com seu potencial para captar uma vasta gama de variáveis objetivas de diversos campos do conhecimento, oferece uma analogia à “convergência poliédrica”, uma vez

que possibilita uma aproximação do formato esférico através da adição de incontáveis faces que delimitam distintas visões objetivas. Nesse contexto, o big data não é apenas um conjunto de tecnologias, mas uma chave metodológica para a expansão do conhecimento.

### 3 *ACHIEVEMENT DRIVE* E AGRESSIVIDADE FISCAL: UMA ANÁLISE EMPÍRICA UTILIZANDO FWHR

#### 3.1 Introdução

O planejamento tributário agressivo<sup>2</sup> se configura como uma ferramenta utilizada pelas empresas para otimizar suas obrigações fiscais, apresentando um complexo balanço entre custos e benefícios. Enquanto podem beneficiar indicadores financeiros de curto prazo, tais práticas implicam em custos não tributários significativos, incluindo a realização de transações complexas que podem comprometer a compreensão e a confiança dos stakeholders. Conforme destacado por Balakrishnan et al. (2019), um planejamento tributário agressivo exige que a companhia disponha de uma sofisticação organizacional e financeira considerável, com seus gestores lidando com o dilema de relatar altos rendimentos aos investidores e, ao mesmo tempo, tentar apresentar lucros reduzidos às autoridades fiscais. Além disso, práticas contábeis agressivas, mesmo que dentro dos limites legais, podem levar a uma degradação na qualidade das informações reportadas, dificultando a análise financeira e influenciando potencialmente o desconto no preço das ações percebido pelos acionistas devido à percepção de agressividade tributária (Chen et al., 2010).

Nesse contexto, a complexa relação entre a gestão fiscal estratégica e a percepção de seus impactos tanto internos quanto externos à organização destaca a importância de uma análise mais aprofundada sobre os fatores que motivam tais decisões. Pesquisas antecedentes investigaram a conexão entre atributos pessoais dos gestores e comportamentos corporativos, demonstrando o impacto significativo que elas exercem sobre o perfil financeiro da empresa (Fee et al., 2013; Greenfield et al., 2008; Labelle et al., 2010). Avanços no estudo do comportamento humano têm motivado a área da gestão a incorporar contribuições de diversos campos do conhecimento, visando enriquecer a compreensão de novas dinâmicas no âmbito empresarial. Hormônios, como a testosterona, têm sido associados a comportamentos relacionados ao risco e à agressividade, com estudos em endocrinologia identificando biomarcadores faciais que podem ser reflexos dessas tendências comportamentais (Carré & McCormick, 2008; Lefevre et al., 2013).

No domínio da governança corporativa, a validade biomarcador *facial width-to-height ratio* (FWHR) como proxy das características comportamentais de CEOs tem sido objeto de debate sobre sua influência nas decisões gerenciais e desempenho das companhias (Ahmed et

---

<sup>2</sup> No decorrer deste artigo, os termos "planejamento tributário agressivo", "elisão fiscal", "agressividade tributária" e "agressividade fiscal" serão empregados de forma intercambiável.

al., 2019; Kamiya et al., 2018). Este artigo visa aprofundar esse debate, explorando a relação entre a elisão fiscal das empresas e a estrutura facial de CEOs e CFOs, ancorado pela seguinte questão norteadora: é possível prever o nível de agressividade fiscal de uma empresa utilizando a fWHR de seus diretores?

A agressividade fiscal foi escolhida por sua relevância multifacetada. Primeiramente, ela se destaca como um fenômeno mensurável, oferecendo uma oportunidade singular para investigar como decisões estratégicas são tomadas dentro do espectro da discricionariedade gerencial. Ademais, a agressividade fiscal encerra em si uma riqueza de consequências econômicas e sociais, desde a influência nas receitas públicas até questões de justiça fiscal, destacando-se como um campo fértil para análises que transcendem o mero aspecto financeiro, como motivações relacionadas à personalidade do agente.

Em contrapartida, o histórico de uma empresa pode revelar padrões de comportamento que são independentes do perfil de seus diretores. A gestão operacional reflete as aspirações de seus acionistas e está sujeita à influência do clima econômico vigente. Para dissecar empiricamente esses efeitos, nossa análise abrange variáveis no nível corporativo, fatores contextuais do tempo, nuances da indústria e características específicas dos diretores.

Utilizando a fWHR calculada por algoritmo de visão computacional como biomarcador facial indicativo de níveis de testosterona, encontramos que diretores com fWHR mais elevada tenderão a adotar estratégias fiscais mais agressivas. Esses achados foram confirmados tanto para CEOs quanto para CFOs, que seriam duas funções envolvidas fortemente no planejamento tributário da empresa.

Nossa metodologia utiliza uma amostra que abrange o período entre 1999 e 2019. As associações permanecem robustas em testes adicionais, contribuindo para a literatura emergente sobre a relação entre marcadores biológicos e tomada de decisão corporativa.

### **3.2 Revisão da Literatura**

O planejamento tributário corporativo refere-se ao conjunto de estratégias que visam à minimização da carga tributária, utilizando de forma legal as lacunas e incentivos oferecidos pela legislação fiscal. Na prática contábil, essas estratégias podem ser fundamentais para a eficiência das empresas, pois impactam diretamente os lucros e os fluxos de caixa. No entanto, elas podem se aproximar de uma zona cinzenta entre elisão e evasão fiscal, quando a agressividade no planejamento busca maximizar os rendimentos dos investidores à custa das receitas fiscais devidas às autoridades.

Considerando que o benefício privado dessas práticas resulta em perdas sociais irreparáveis, prejudicando milhões de pessoas, empresas socialmente responsáveis evitariam estratégias agressivas em seu planejamento tributário (Sikka, 2010). Lanis e Richardson (2012) destacam que a responsabilidade social corporativa (RSC) implica que as empresas não devem adotar práticas de elisão fiscal agressiva, pois o pagamento de impostos garante o financiamento de bens públicos e a vitalidade econômica de uma sociedade.

Apesar disso, Davis et al. (2016) demonstram em estudo empírico que, embora essas empresas possam parecer menos propensas a evasão fiscal, na prática, muitas vezes tratam a RSC como um substituto, e não um complemento ao pagamento de tributos. Nesse contexto, os gestores são desafiados a alinhar as estratégias de planejamento tributário com as expectativas dos stakeholders, ao mesmo tempo que enfrentam a pressão por um bom desempenho financeiro. De um lado, devem atender aos investidores maximizando o retorno, e, de outro, mitigar os riscos de sanções e danos à reputação da empresa perante as autoridades fiscais. Assim, um planejamento tributário eficaz não é meramente uma questão de conformidade contábil, mas sim uma estratégia na qual os gestores enfrentam um dilema entre a maximização dos rendimentos para os investidores e a minimização para as autoridades fiscais (Schwab et al., 2022).

À medida que a agressividade fiscal aumenta, o risco de ultrapassar o limiar da legalidade torna-se iminente. Nesse cenário, estratégias excessivamente agressivas podem ser consideradas evasão fiscal, resultando em penalidades, perda de reputação e danos à sustentabilidade da empresa. Esse comportamento se alinha à noção de risco, onde a disposição para a agressividade reflete diretamente na escolha de estratégias fiscais que se aproximam do limiar da legalidade, colocando a empresa em uma zona de vulnerabilidade regulatória.

Nesse contexto, Kovermann e Wendt (2019) exploram a relação entre governança corporativa e agressividade fiscal, demonstrando que o perfil do CEO e sua tolerância ao risco moldam profundamente as decisões de planejamento tributário. Esse achado é complementado por estudos como o de Dyreng et al. (2010), que destacam o impacto significativo do perfil dos executivos nas estratégias fiscais e nos resultados das empresas.

Pesquisas têm demonstrado que CEOs mais propensos a assumir riscos tendem a fomentar políticas de investimento mais agressivas e, em alguns casos, adotam práticas contábeis questionáveis, refletindo a interação intrínseca entre as características individuais dos líderes e as estratégias corporativas. A literatura endocrinológica e biogenética reforça que os níveis hormonais, especialmente a testosterona, desempenham um papel fundamental na

formação de comportamentos relacionados à agressividade e à predisposição ao risco (Carré & McCormick, 2008; Lefevre et al., 2013).

Em experimento laboratorial, Verdonck et al. (1999) observaram que a administração de testosterona em adolescentes com puberdade tardia aumentou significativamente o crescimento craniofacial, incluindo a altura facial e o comprimento mandibular. Esses achados sugerem que a estrutura facial reflete diretamente níveis hormonais que influenciam comportamentos decisivos e competitivos. Assim, a fWHR emergiu como um indicador de características comportamentais associadas à testosterona, incluindo o *achievement drive*, ou impulso de conquista, que está fortemente relacionado a comportamentos competitivos e de alto risco.

No campo da psicologia comportamental, Pound et al. (2009), Ahmed et al. (2019) e Jia et al. (2014) ampliam essa discussão, vinculando características faciais a decisões arriscadas. Com base nessas observações, levantamos a seguinte hipótese: diretores com maior fWHR, indicativo de níveis mais altos de testosterona, apresentam maior propensão a adotar estratégias de planejamento tributário agressivas.

A importância do CFO nesse contexto não pode ser subestimada. Ben-David et al. (2013) e Florackis e Sainani (2021) reconhecem que o CFO pode ter um papel igualmente ou mais significativo do que o CEO em algumas decisões corporativas. Kamiya et al. (2018) demonstram que tanto a fWHR do CFO quanto a do CEO influenciam o risco empresarial. Além disso, Dechow et al. (2011), ao examinarem relatórios de fiscalização da SEC (os AAERs), destacam que em casos de manipulação contábil, os CFOs frequentemente são citados. Diante desses argumentos, a hipótese será testada separadamente utilizando a fWHR do CEO e a do CFO.

### **3.3 Procedimentos metodológicos**

#### **3.3.1 Dados e Amostra**

Nossa amostra foi composta por dados extraídos das bases de dados Compustat North America e Execucomp, e dos sites oficiais das empresas dessas bases. Por meio da Execucomp, construímos uma amostra com dados anuais referentes aos CEOs e CFOs no período de 1999 a 2019 para cada empresa da América do Norte e os relacionamos com os dados financeiros da Compustat.

Para a identificação da fWHR, buscamos as fotos dos CEOs e dos CFOs identificados na Execucomp nos relatórios anuais e sites oficiais das empresas, além do site Bloomberg.com e por último no Google Imagens, até encontrarmos no mínimo três fotos em uma posição

adequada para cada CEO. A posição adequada é aquela em que é possível visualizar completamente a face, incluindo as duas orelhas. Calculamos a razão largura/altura facial por meio de um algoritmo desenvolvido em Python, que exclui fotos em resolução insuficiente e criamos as variáveis contínuas fWHR (CEO) e fWHR (CFO). Os procedimentos de coleta, normalização das imagens, detecção dos pontos de referência e cálculo da fWHR em Python estão descritos no Apêndice A.

Conseguimos calcular adequadamente 1.920 estruturas faciais de diretores distintos, sendo que 76 deles atuaram durante o período nas duas funções, gerando 1.379 imagens de CEOs e 617 de CFOs. A proporção de CEOs com fotos adequadas foi significativamente maior do que a de CFOs. Isso já foi relatado em pesquisas anteriores e ocorre porque os CEOs são figuras mais proeminentes como representantes de suas empresas, estando mais expostos à mídia (Kamiya et al. 2019). A Tabela 1 descreve resumidamente o processo de seleção da amostra, que resultou em 7.189 observações empresa-ano.

**Tabela 1**  
*Amostra da pesquisa*

	Obs	Empresas	CEOs	CFOs
Amostra inicial de 1999 a 2019	10.434	1.297	1.379	617
(-) empresas do setor financeiro	1.339	159		
(-) dados faltantes (variáveis dependentes)	1.906	86	239	99
(=) amostra final	7.189	1.052	1.140	518

### 3.3.2 Medidas de agressividade fiscal

A escolha das proxies para medir a agressividade fiscal em nossa pesquisa segue a tradição da literatura contábil, que reconhece a inexistência de uma definição universalmente aceita para esse construto (Hanlon & Heitzman, 2010; Lennox et al., 2012). Dado que cada medida possui suas vantagens e limitações, utilizamos seis variáveis distintas para capturar essa complexidade: três baseadas nas diferenças entre o lucro contábil e o lucro tributável (BTD) e três na taxa efetiva de imposto (ETR). Um alto nível de BTD (*Book-tax Differences*) pode indicar que a empresa está se engajando em planejamento tributário agressivo para reduzir sua carga tributária, aproveitando-se de lacunas nas leis fiscais. Já a ETR (*Effective Tax Rate*) oferece uma visão direta da parcela de lucros da empresa que é alocada para pagar impostos. A seguir, detalhamos cada uma dessas medidas, cujas fórmulas de cálculo estão descritas no Apêndice B.

As três medidas de BTD incluem BTD Total, BTD Permanente e BTD Discricionária. A BTD Total reflete a diferença entre o lucro contábil e o lucro tributável, oferecendo uma visão

abrangente das estratégias de planejamento tributário da empresa, que podem incluir tanto diferenças temporárias quanto permanentes. A BTD Permanente isola as diferenças permanentes, focando em estratégias que impactam de forma contínua, reduzindo a carga tributária ao longo do tempo. Por fim, a BTD Discricionária, conforme proposta por Frank et al. (2009), busca capturar a parcela discricionária das diferenças permanentes, refletindo as práticas que resultam de decisões gerenciais intencionais, que podem incluir estratégias para minimizar a base tributável ou manipular o lucro contábil.

No que tange às medidas baseadas na ETR, utilizamos a ETR GAAP e a Cash ETR de Longo Prazo calculada com os períodos de três anos ( $t_2$  a  $t_0$ ) e cinco anos ( $t_4$  a  $t_0$ ). A ETR GAAP é calculada pela divisão das despesas com tributos sobre o lucro pelo lucro antes dos tributos, representando a alíquota efetiva dos tributos sobre o lucro da empresa. Já a Cash ETR (*Cash Effective Tax Rate*) proposta por Dyreng et al. (2008) considera apenas os tributos efetivamente pagos, e é analisada em um horizonte de longo prazo. Calculamos duas variáveis com base nessa alíquota, utilizando as médias das despesas tributárias registradas nos últimos três e cinco anos por empresa e dividindo pela média lucro antes dos tributos nos mesmos períodos.

A Tabela 2 apresenta as diferenças dessas métricas pelos setores das empresas. Essa variedade de proxies nos permite triangular evidências capturando tanto as reações imediatas quanto as estratégias de longo prazo, oferecendo uma perspectiva sobre a cultura fiscal da empresa e o compromisso da liderança com estratégias de planejamento tributário. A Cash ETR de longo prazo ajuda a suavizar efeitos temporários e anomalias, fornecendo uma base mais estável para a análise da postura fiscal das empresas e sua aderência a estratégias fiscais agressivas ou conservadoras ao longo do tempo (Dyreng et al., 2008).

**Tabela 2**

*Variáveis dependentes por setor*

Código SIC	Setor	Empresas	Empresa ano	Valores médios por proxy				
				BT Totais	BT Perm	BT Disc	ET GAAP	Cash ET
0100-0999	Agricultura	4	31	0,016	0,010	-0,001	0,254	-0,143
1000-1999	Mineração e extração	80	684	-0,012	-0,013	-0,001	0,416	0,172
2000-3999	Manufatura	505	4.019	0,003	0,008	0,001	0,324	0,195
4000-4999	Transporte, comunicação	101	813	0,003	-0,011	0,001	0,216	0,627
5000-5999	Comércio atacadista e varejista	142	1.112	0,005	0,004	-0,001	0,297	0,216
6000-6499	Serviços financeiros, seguradoras	159	1.339	0,012	0,009	0,048	0,300	0,286
6500-7099	Serviços imobiliários	83	731	0,018	0,021	0,006	0,043	0,123
7100-9999	Outros serviços	223	1.705	0,005	0,009	0,001	0,247	0,252
Amostra total		1.297	10.434	0,004	0,006	0,001	0,281	0,245



### 3.3.3 Especificação do modelo de efeitos fixos

Para testar nossa primeira hipótese, utilizamos um modelo de Mínimos Quadrados Ordinários (MQO), cuja especificação é dada por

$$TaxAgress_{it} = \beta_0 + \beta_1 fWHR_{it} + \beta_2 X_{it} + \theta_t + \tau_i + \varepsilon_{it} \quad (1)$$

onde  $TaxAgress_{it}$  representa nossas seis variáveis dependentes da empresa  $i$  no ano  $t$ , testadas separadamente; o coeficiente  $\beta_1$  captura o efeito da  $fWHR$  do CEO ou CFO da firma  $i$  no ano  $t$  na variável dependente;  $X_{it}$  representa um vetor de variáveis de controle no nível do CEO ou CFO e da firma;  $\theta_t$  são os efeitos fixos do tempo (ano);  $\tau_i$  representa o efeito fixo do setor e  $\varepsilon_{it}$  o termo de erro robusto à heteroscedasticidade.

Utilizando essa especificação, aplicamos o teste de Hausman para comparar modelos de efeitos fixos e aleatórios. Os resultados do teste indicaram a rejeição da hipótese nula, sugerindo que o modelo de efeitos fixos é mais adequado para nossas análises. Devido à presença de heteroscedasticidade identificada pelo teste de White, ajustamos os erros-padrão dos coeficientes para torná-los robustos a essa condição.

As variáveis de controle ao nível do executivo foram selecionadas com base em estudos anteriores que examinam o impacto das características dos diretores na estratégia e no desempenho organizacional. Para capturar a influência da experiência e do perfil demográfico do executivo, incluímos a idade do CEO (AGE), que pode impactar a propensão ao risco e a capacidade de inovação, o tempo de mandato (TEN) e o sexo (GEN), que podem influenciar o estilo de liderança e a tomada de decisões (Adams & Funk, 2012; Dechow & Sloan, 1991; James, 2020; Jbir et al., 2021). Incorporamos também o *interlock* (INTL), que representa a presença do CEO em múltiplos conselhos, indicando sua influência e rede dentro do setor (Minnick & Noga, 2010; Rönkkö et al., 2023).

Controlamos também por variáveis ao nível da empresa, consideradas pela literatura contábil como determinantes da agressividade fiscal. O tamanho do conselho de administração (BRD), o tamanho da organização (SIZE), a relação Market-to-Book Ratio (MTB), o crescimento das vendas (GRW), e a liquidez (LIQ) são incluídos nas regressões, pois estudos demonstram que empresas maiores, com maior potencial de crescimento e liquidez, tendem a ter mais recursos e incentivos para empregar estratégias de elisão fiscal (Dyreng et al., 2010; Guenter et al., 2019; Mills et al., 1998). Além disso, quanto maior o board, mais difícil o consenso (Minnick & Noga, 2010; Rönkkö, 2023).

Adicionalmente, consideramos o nível de despesas de capital (CAPx), uma vez que empresas com maiores investimentos em bens de capital podem empregar estratégias

específicas para evitar impostos, e a alavancagem (LEV), dado que empresas mais alavancadas podem ter incentivos para maximizar os benefícios fiscais associados ao financiamento via dívida (Graham & Tucker, 2006).

Por fim, utilizamos uma dummy que indica a existência de prejuízos a serem compensados (NOL), bem como uma variável contínua que captura a variação dessas perdas ao longo do tempo ( $\Delta$ NOL), pois o uso de prejuízos operacionais acumulados e sua alteração ao longo do tempo podem afetar significativamente a carga tributária (Badertscher et al., 2019; Chen et al., 2010). Além dessas, a tangibilidade dos ativos (TAN) foi incluída, pois empresas com mais ativos tangíveis podem ter menos flexibilidade para evitar impostos; e por último, a indicadora MULT foi utilizada para indicar se a empresa possui operações no exterior, considerando que multinacionais têm mais oportunidades de planejamento tributário internacional (Dyreg et al., 2019).

Como utilizamos variáveis dependentes com diferentes escalas de medida, estimamos os betas padronizados, conforme a Equação 2. O uso de coeficientes padronizados permite comparar diretamente as magnitudes dos efeitos das diversas proxies, independentemente das escalas em que essas variáveis foram medidas.

$$bStdXY = b \times \frac{\sigma_x}{\sigma_y} \quad (2)$$

onde  $b$  é o coeficiente da regressão estimado para a variável  $X$ ;  $\sigma_x$  é o desvio padrão da variável  $X$ ; e  $\sigma_y$  é o desvio padrão da variável  $Y$ . Todas as variáveis contínuas usadas no modelo foram winsorizadas no 1º e 99º percentis para reduzir o efeito de outliers. O Apêndice B descreve as formas de cálculo e fonte de dados de cada variável.

### 3.3.4 Especificação do modelo multinível

Para verificação de robustez dos resultados, aplicamos um modelo hierárquico linear (HLM) que captura variações nas decisões dos executivos em múltiplos níveis — observações individuais e em grupos de diretores e empresas — distinguindo influências dos CEOs / CFOs das características estruturais das empresas. O modelo utilizado pode ser expresso por

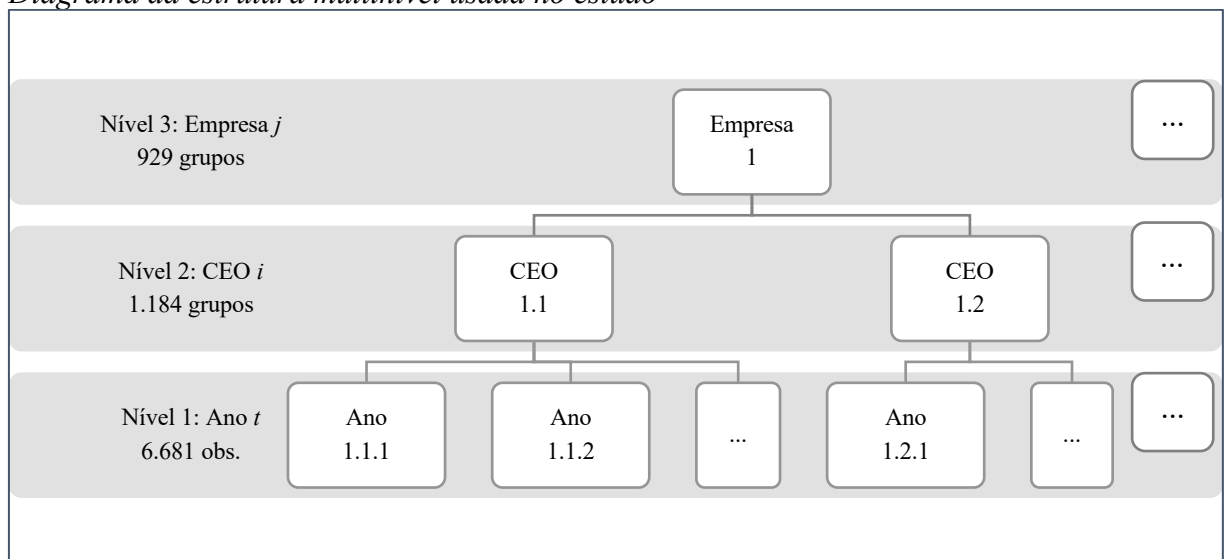
$$TaxAgress_{tij} = \gamma_{000} + \gamma_{0ij} + \gamma_{00j} + \gamma_{1ij}fWHR_{tij} + \gamma_n \sum X_{tij} + \theta_t + \tau_i + (\mu_{0ij} + \tau_{00j} + \varepsilon_{tij}) \quad (3)$$

onde  $\gamma_{000}$  é o intercepto da parte fixa, a média geral no nível da observação individual (ano);  $\gamma_{0ij}$  e  $\gamma_{00j}$  são os interceptos nos níveis de grupos (nesta ordem: diretor e empresa);  $\gamma_{1ij}$  captura o efeito da fWHR (nosso resultado de interesse), que pode ser do CEO ou do CFO (variáveis

fCEO e CFO em nossas regressões);  $X_{tij}$  representa um vetor de variáveis de controle no nível do diretor e da firma;  $\theta_t$  e  $\tau_i$  são os efeitos fixos de ano e de setor. Os três termos na parte destacada entre parênteses representam os componentes aleatórios, com as três fontes de variância:  $\mu_{0ij}$  = efeitos aleatórios do diretor;  $\tau_{00j}$  = efeitos aleatórios da empresa e  $\varepsilon_{tij}$  = termo de erro correlacionado ao erro do ano anterior.

A Figura 3 apresenta o diagrama que ilustra os níveis do modelo, com as quantidades de grupos referentes ao modelo que utiliza a variável ETR-GAAP como dependente, após a exclusão das observações que não atendem aos critérios da pesquisa. A quantidade de CEOs não corresponde ao dobro do número de empresas, pois alguns CEOs atuaram em diferentes empresas ao longo do período analisado.

**Figura 3**  
Diagrama da estrutura multinível usada no estudo



Nota. Adaptado de Monsalves et al. (2020)

### 3.4 Resultados empíricos

O resumo estatístico das variáveis independentes contínuas está relatado no Painel A da Tabela 3. A amostra revela que, em média, os CEOs e CFOs possuem uma fWHR de aproximadamente 2,24 e 2,26, respectivamente. A distribuição dessas variáveis é consistente, conforme indicado pela média e os quartis. Outros fatores, como o *market-to-book ratio* (MTB) e a idade dos diretores (AGE), mostram uma variação significativa, refletindo a diversidade da amostra em termos de características empresariais e de liderança.

**Tabela 3***Resumo estatístico**Painel A - Estatística descritiva das variáveis contínuas usadas no estudo*

Variável	N	Média	DP	p25	p50	p75
<i>Variáveis dependentes</i>						
<b>BTDTtotal</b>	5.491	0,003	0,083	-0,018	0,014	0,041
<b>BTDPperm</b>	5.489	0,005	0,093	-0,009	0,010	0,033
<b>BTDDisc</b>	5.421	0,001	0,203	-0,030	0,008	0,043
<b>ETR-GAAP</b>	6.681	0,476	0,320	0,265	0,356	0,891
<b>CETR3anos<sup>a</sup></b>	4.461	0,332	0,237	0,181	0,280	0,398
<b>CETR5anos</b>	2.671	0,311	0,200	0,183	0,272	0,377
<i>Variáveis de interesse</i>						
<b>fCEO</b>	6.582	2,247	0,160	2,139	2,241	2,347
<b>fCFO</b>	2.651	2,259	0,157	2,158	2,253	2,360
<i>Nível do CEO</i>						
<b>AGE<sup>b</sup></b>	6.582	55,275	7,305	50	55	60
<b>TEN<sup>b</sup></b>	6.582	7,946	7,692	2,512	5,331	10,915
<i>Nível do CFO</i>						
<b>AGE<sup>b</sup></b>	2.651	50,152	6,748	46	50	55
<i>Nível da empresa</i>						
<b>BRD</b>	6.582	5,571	1,142	5	5	6
<b>SIZE</b>	6.582	7,709	1,637	6,538	7,606	8,820
<b>TAN</b>	6.582	0,519	0,449	0,192	0,398	0,757
<b>LIQ</b>	6.582	2,367	1,857	1,260	1,832	2,767
<b>GRW</b>	6.582	0,072	0,195	0,000	0,036	0,126
<b>CAPx</b>	6.582	0,048	0,047	0,018	0,034	0,060
<b>MTB</b>	6.582	3,438	5,101	1,511	2,468	4,089
<b>LEV</b>	6.582	0,253	0,236	0,073	0,234	0,366
<b>ΔNOL</b>	6.582	0,132	0,750	0	0	0

*Painel B - Diferenças de médias por proxy*

	fwhr CEO(-)	fwhr CEO(+)	Teste t	fwhr CFO(-)	fwhr CFO(+)	Teste t
<b>BTDTtotal</b>	0,001	0,006	-2,95***	-0,005	0,012	-4,87***
<b>BTDPperm</b>	0,002	0,007	-1,90*	-0,003	0,014	-4,33***
<b>BTDDisc</b>	-0,004	0,005	-1,69*	0,007	0,009	-0,26
<b>ETR</b>	0,369	0,254	1,15	0,448	0,281	0,75
<b>CETR</b>	0,297	0,218	0,58	0,216	0,520	-0,96
<b>CETR3anos</b>	0,435	0,427	0,91	0,457	0,379	6,19***

*Notas.*

<sup>a</sup> Nos modelos estimados, a proxy Cash Etr (CETR) foi utilizada na forma de longo prazo, calculando-se a média de três e de cinco anos. Os valores do período de cinco anos foram semelhantes aos do período de três anos.

<sup>b</sup> Devido à alta variância dos dados referentes às idades dos diretores (AGE) e ao mandato do CEO (TEN), elas foram utilizadas nas regressões na forma logarítmica.

No Painel B, os testes de diferenças de médias entre grupos de CEOs e CFOs com fWHR acima e abaixo da mediana oferecem insights valiosos sobre o impacto potencial dessas características físicas nos resultados fiscais. Os resultados mostram que a BTB total é positiva tanto para CEOs com fWHR alta quanto para aqueles com fWHR baixa, sugerindo que o lucro contábil excede o lucro tributável, independentemente da estrutura facial. Contudo, a diferença entre os CFOs é mais pronunciada, com mudança de sinal, o que pode indicar um papel mais significativo do CFO na determinação da BTB do que o CEO.

Em três proxies, as diferenças foram estatisticamente significativas, tanto para CEOs quanto para CFOs, dando indícios preliminares que a fWHR influencia a agressividade tributária das empresas. Os CFOs com alta fWHR mostraram uma diferença maior e significativa em duas variáveis, sinalizando que a influência do CFO pode ser mais determinante do que o CEO nessas métricas.

A Tabela 4 demonstra que a colinearidade entre as variáveis não é um problema, com os valores do VIF (*Variance Inflation Factor*) sendo todos inferiores a 2. Isso indica que as variáveis utilizadas no modelo de regressão são suficientemente distintas e não comprometem a robustez das inferências.

**Tabela 4***Matriz de correlação e estatística VIF (Variance Inflation Factor)*

	VIF	fCEO	fCFO	AGEceo	AGEcfo	GENceo	GENcfo	TEN	BRD	SIZE	TAN	LIQ	GRW	CAPx	MTB	LEV	NOL	dNOL
fCEO	1,06	1																
fCFO	1,03	<b>0,101</b>	1															
AGEceo	1,23	-0,01	<b>-0,056</b>	1														
AGEcfo	1,09	-0,003	0,004	<b>0,165</b>	1													
GENceo	1,05	<b>-0,057</b>	-0,032	<b>0,034</b>	0,027	1												
GENcfo	1,06	-0,006	<b>-0,071</b>	0,006	<b>0,037</b>	<b>0,084</b>	1											
TEN	1,25	<b>-0,024</b>	0,016	<b>0,364</b>	<b>0,077</b>	<b>0,088</b>	0,032	1										
BRD	1,06	-0,013	0,017	<b>-0,045</b>	0,007	0,006	<b>-0,041</b>	<b>-0,159</b>	1									
SIZE	1,31	-0,014	-0,002	<b>0,112</b>	<b>0,193</b>	<b>-0,055</b>	<b>-0,037</b>	<b>-0,049</b>	<b>0,146</b>	1								
TAN	1,85	-0,001	-0,011	<b>0,08</b>	<b>0,033</b>	<b>-0,028</b>	0,021	<b>-0,065</b>	<b>0,06</b>	<b>-0,027</b>	1							
LIQ	1,25	<b>-0,037</b>	<b>-0,046</b>	-0,011	0	<b>0,025</b>	0,012	<b>0,111</b>	<b>-0,121</b>	<b>-0,379</b>	<b>-0,218</b>	1						
GRW	1,10	0,014	0,022	<b>-0,059</b>	<b>-0,044</b>	<b>0,02</b>	0	<b>0,091</b>	<b>-0,059</b>	<b>-0,032</b>	<b>-0,134</b>	<b>0,043</b>	1					
CAPx	1,74	-0,01	<b>-0,031</b>	-0,014	<b>-0,069</b>	-0,015	<b>0,029</b>	<b>-0,028</b>	<b>0,077</b>	<b>-0,11</b>	<b>0,622</b>	<b>-0,143</b>	<b>0,033</b>	1				
MTB	1,08	-0,001	<b>0,036</b>	<b>-0,078</b>	<b>0,04</b>	<b>-0,049</b>	0,001	0,006	<b>0,03</b>	<b>-0,039</b>	<b>-0,089</b>	0,003	<b>0,117</b>	0,016	1			
LEV	1,23	<b>-0,058</b>	0,017	-0,016	<b>0,048</b>	<b>0,032</b>	<b>0,051</b>	<b>-0,045</b>	<b>0,022</b>	<b>0,189</b>	<b>0,155</b>	<b>-0,318</b>	<b>-0,037</b>	<b>0,018</b>	<b>-0,083</b>	1		
NOL	1,09	<b>-0,024</b>	-0,003	<b>-0,035</b>	0,016	<b>-0,017</b>	0,005	<b>-0,055</b>	-0,007	<b>-0,082</b>	-0,01	0,016	0,007	-0,001	<b>0,039</b>	<b>0,049</b>	1	
ΔNOL	1,03	-0,004	-0,015	<b>-0,018</b>	-0,016	0,011	-0,002	-0,008	<b>0,019</b>	0,005	-0,007	0,01	<b>0,041</b>	0,006	0,005	<b>0,022</b>	<b>0,153</b>	1
MULT	1,27	-0,001	<b>-0,05</b>	<b>-0,027</b>	<b>0,103</b>	<b>-0,018</b>	-0,018	<b>-0,08</b>	<b>0,085</b>	<b>0,033</b>	<b>-0,07</b>	<b>0,077</b>	<b>-0,065</b>	<b>-0,071</b>	<b>0,07</b>	<b>-0,045</b>	<b>0,337</b>	<b>0,07</b>

*Notas.* Os coeficientes de correlação para os pares com significância estatística a 1% estão destacados em negrito.

Para a estatística VIF, foram realizadas três regressões separadas: uma considerando apenas os atributos dos CEOs, outra com os atributos dos CFOs, e uma terceira com todas as variáveis incluídas simultaneamente. Em todas as regressões, os valores médios de VIF foram consistentemente baixos, com médias de 1,24; 1,21 e 1,21, respectivamente, indicando ausência de problemas significativos de multicolinearidade. Os resultados apresentados na Tabela 4 referem-se ao modelo estimado com todas as variáveis consideradas. Vale destacar que, para as variáveis de Idade e Mandato do CEO, utilizou-se o logaritmo natural para a normalização dos dados.

### 3.4.1 Relação entre *fWHR* do CEO e agressividade fiscal corporativa

A Tabela 5 apresenta os resultados das regressões por efeitos fixos, analisando o impacto da *fWHR* do CEO (*fCEO*) sobre as proxies de agressividade tributária. Para facilitar a interpretação dos resultados, as três últimas proxies foram multiplicadas por menos um. Além disso, a idade (*AGE*) e o mandato do CEO (*TEN*) foram utilizados em formato logarítmico. Incluímos efeitos fixos de setor (*SIC* de dois dígitos) e ano para controle da heterogeneidade não observada ao longo do tempo e diferenças entre setores. Utilizamos erros-padrão robustos à heterocedasticidade visando fortalecer a confiabilidade.

Os resultados das regressões revelam que o coeficiente de *fCEO* mostra-se consistentemente positivo e estatisticamente significativo nos seis modelos, apontando para uma correlação positiva entre a *fWHR* do CEO e a agressividade tributária da empresa. Essa relação é um indicativo de que características físicas, como a *fWHR*, podem estar intrinsecamente ligadas a comportamentos mais agressivos e à propensão ao risco, conforme evidenciado em estudos anteriores (Kamiya et al., 2019). Já quanto à idade do CEO (*AGE*), observamos que, embora não seja estatisticamente significativa na maioria das variáveis dependentes, ela se destaca positivamente no modelo 4, resultado contrário ao encontrado por James (2019).

**Tabela 5**  
*Efeito da fWHR do CEO na agressividade tributária*

	<u>BTD-Total</u>	<u>BTD-Perm</u>	<u>BTD-Disc</u>	<u>ETR-GAAP</u>	<u>CashETR-3a</u>	<u>CashETR-5a</u>
	(1)	(2)	(3)	(4)	(5)	(6)
<b>fCEO</b>	<b>0,024***</b> (0,002)	<b>0,016*</b> (0,056)	<b>0,038*</b> (0,059)	<b>0,064***</b> (0,009)	<b>0,072***</b> (0,003)	<b>0,077***</b> (0,004)
<b>AGE</b>	0,003 (0,771)	-0,010 (0,437)	0,044 (0,141)	0,108*** (0,001)	0,005 (0,873)	-0,009 (0,803)
<b>GEN</b>	0,000 (0,938)	-0,004 (0,382)	-0,001 (0,830)	-0,013 (0,531)	0,029 (0,182)	0,026 (0,277)
<b>TEN</b>	0,003* (0,063)	0,003* (0,067)	0,001 (0,803)	0,021*** (0,000)	0,031*** (0,000)	0,028*** (0,000)
<b>INTL</b>	0,028*** (0,000)	0,026*** (0,001)	0,039** (0,013)	0,066** (0,028)	0,074*** (0,008)	0,059* (0,059)
<b>BRD</b>	-0,003** (0,011)	-0,002 (0,105)	-0,003 (0,242)	-0,018*** (0,000)	-0,013*** (0,001)	-0,010** (0,017)
<b>SIZE</b>	0,010*** (0,000)	0,011*** (0,000)	0,013*** (0,000)	0,044*** (0,000)	0,047*** (0,000)	0,046*** (0,000)
<b>TAN</b>	-0,013* (0,069)	-0,015*** (0,008)	-0,031* (0,055)	-0,072*** (0,000)	-0,108*** (0,000)	-0,100*** (0,000)
<b>LIQ</b>	0,004*** (0,000)	0,004*** (0,000)	0,007** (0,018)	0,004 (0,116)	0,006** (0,019)	0,003 (0,351)

<b>GRW</b>	0,030*** (0,001)	0,038*** (0,000)	0,043* (0,056)	0,098*** (0,000)	0,045* (0,054)	-0,009 (0,718)
<b>CAPx</b>	0,207*** (0,000)	0,120*** (0,006)	0,228** (0,012)	0,836*** (0,000)	1,039*** (0,000)	0,709*** (0,000)
<b>MTB</b>	0,000 (0,299)	0,000 (0,286)	-0,000 (0,885)	0,004*** (0,000)	0,002** (0,048)	0,000 (0,767)
<b>LEV</b>	-0,034*** (0,000)	-0,035*** (0,000)	-0,025 (0,106)	-0,111*** (0,000)	-0,098*** (0,000)	-0,095*** (0,000)
<b>NOL</b>	-0,003 (0,274)	-0,002 (0,360)	-0,010** (0,039)	-0,043*** (0,000)	-0,037*** (0,000)	-0,042*** (0,000)
<b>ΔNOL</b>	-0,015*** (0,000)	-0,013*** (0,000)	-0,025*** (0,000)	-0,030*** (0,000)	-0,015*** (0,002)	-0,006 (0,229)
<b>MULT</b>	-0,001 (0,806)	0,001 (0,762)	0,008 (0,345)	-0,008 (0,452)	-0,038*** (0,000)	-0,050*** (0,000)
<b>_cons</b>	-0,134*** (0,005)	-0,071 (0,196)	-0,354*** (0,008)	-1,288*** (0,000)	-0,915*** (0,000)	-0,831*** (0,000)
<b>Obs</b>	5491	5489	5421	6681	4461	2671
<b>R<sup>2</sup> ajust</b>	0,108	0,091	0,013	0,144	0,201	0,248

Nota. Valores p estão entre parênteses

\*\*\* p<0,01, \*\* p<0,05, \* p<0,1

O mandato do CEO (TEN) se mostra relevante em quase todas as regressões, sinalizando que CEOs com mais experiência no cargo tendem a adotar estratégias fiscais mais agressivas. A variável binária INTL (*interlocking*), que indica se o CEO possui vínculos com outros conselhos, é positiva e significativa em todas as regressões. Esse resultado pode ser explicado pelo efeito de rede que esse vínculo proporciona, ampliando as oportunidades e influências em práticas gerenciais agressivas (Ferris et al., 2003).

O tamanho da empresa (SIZE) apresenta coeficientes positivos e significativos, sugerindo que empresas maiores tendem a adotar práticas fiscais mais agressivas. Em contraste, o tamanho do conselho (BRD) apresenta um efeito negativo e significativo em várias das proxies de agressividade tributária, o que pode indicar que conselhos maiores exercem uma função de governança mais eficaz, limitando práticas tributárias excessivamente arriscadas (Minnick & Noga, 2010).

O coeficiente referente à tangibilidade dos ativos (TAN) captura a propensão das empresas com mais ativos físicos de adotarem menos estratégias fiscais agressivas, ao passo que a liquidez (LIQ) é significativa e positiva em algumas regressões, indicando que empresas com maior liquidez podem ter mais flexibilidade para adotar essas práticas. Presumimos relação semelhante para empresas em expansão (GRW) e empresas com maiores investimentos em bens de capital (CAPx), sendo o efeito desta última o de maior magnitude em todos os modelos.



Observamos também que a alavancagem (LEV) tem um efeito negativo significativo em várias proxies, sugerindo que empresas mais alavancadas podem ser mais cautelosas em seu planejamento tributário. Quanto ao registro de perdas operacionais líquidas (NOL) e a magnitude de sua variação ( $\Delta$ NOL), a maioria dos modelos aponta para um impacto estatisticamente significativo na estratégia fiscal corporativa.

De acordo com a literatura, as empresas com saldos de NOL têm a capacidade de adiar o pagamento de impostos, o que pode resultar em uma menor ETR no curto prazo, enquanto  $\Delta$ NOL pode indicar mudanças nas oportunidades de adiamento de impostos de um ano para o outro. Empresas com saldo de perdas operacionais acumulado possuem menos incentivos para engajar-se em práticas de elisão fiscal, pois esse saldo pode ser utilizado para compensar lucros futuros, reduzindo assim a necessidade de reduzir a carga tributária por meio de estratégias agressivas. Além disso, tais empresas geralmente enfrentam menor pressão para reportar lucros elevados aos acionistas, o que pode diminuir o incentivo para manipular o lucro contábil em relação ao lucro tributável, apresentando ETRs mais altas e BTDs mais baixas (Graham et al., 2017; Wilson, 2009).

### **3.4.2 *Análise do efeito da fWHR do CFO***

Na Tabela 6, que apresenta os resultados das regressões para a fWHR do CFO, a variável fCFO mostra-se positivamente significativa em relação a cinco dos seis modelos estimados, sugerindo que a estrutura facial do CFO tem uma correlação robusta com as estratégias de agressividade tributária da empresa, semelhante ao observado com o CEO na Tabela 5.

Em dados brutos, a magnitude dos coeficientes do fCFO para BTD total (0,041) e BTD permanente (0,043) é ligeiramente superior à observada para o fCEO (0,024 e 0,016, respectivamente), sinalizando que o impacto do CFO pode ser tão ou mais significativo do que o do CEO em algumas dimensões da agressividade tributária. Esse resultado é coerente com a literatura que destaca a relevância do CFO nas decisões financeiras e tributárias corporativas. Ben-David et al. (2013) argumentam que as decisões financeiras são frequentemente influenciadas pelo CFO, especialmente em áreas como planejamento tributário e gestão de caixa, onde o CFO pode exercer maior controle do que o CEO. Outros autores como Frank e Goyal (2007) e Kamiya et al. (2019) destacam também que, em algumas circunstâncias, o impacto do CFO pode superar o do CEO devido à sua expertise técnica e ao controle direto sobre as operações financeiras.

A magnitude dos coeficientes para fCFO nas proxies de ETR também reflete essa tendência, com coeficientes mais elevados do que os observados para o fCEO. Esses achados

sublinham a importância do CFO nas decisões fiscais da empresa e corroboram a literatura que sugere que o papel do CFO pode ser crucial na definição das estratégias de planejamento tributário. A presença de CFOs com características associadas ao *achievement drive*, como um fWHR elevado, pode indicar uma maior propensão para adotar práticas fiscais agressivas, reforçando a necessidade de considerar o impacto tanto do CEO quanto do CFO nas análises sobre agressividade tributária corporativa.

A única proxy em que não foi encontrada significância estatística foi a BTD discricionária, o que pode ser justificado por vários fatores teóricos e empíricos relacionados à natureza das responsabilidades de cada executivo dentro da empresa e à literatura existente sobre o papel desses líderes na determinação das políticas corporativas. Por refletir decisões gerenciais que envolvem maior grau de julgamento a variação nessa proxy pode ser atribuída fortemente ao CEO.

Embora o CFO desempenhe um papel fundamental na implementação de políticas fiscais, sua função é muitas vezes mais orientada para a execução do que para a formulação de estratégias de alto nível. Em sua pesquisa sobre o reflexo do estilo do CFO nas escolhas contábeis, Ge et al. (2011) defendem que os CFOs são mais propensos a focar na precisão e conformidade dos relatórios financeiros, o que pode limitar sua influência sobre as práticas fiscais mais discricionárias.

**Tabela 6**

*Efeito da fWHR do CFO na agressividade tributária*

	BTD-Total	BTD-Perm	BTD-Disc	ETR-GAAP	CashETR-3a	CashETR-5a
	(1)	(2)	(3)	(4)	(5)	(6)
<b>fCFO</b>	<b>0,041***</b> (0,000)	<b>0,043***</b> (0,001)	-0,004 (0,911)	<b>0,098**</b> (0,014)	<b>0,158***</b> (0,000)	<b>0,189***</b> (0,000)
<b>AGE</b>	0,013 (0,381)	0,011 (0,521)	0,085 (0,192)	0,078 (0,120)	0,090* (0,055)	0,073 (0,183)
<b>GEN</b>	0,003 (0,621)	-0,002 (0,713)	-0,000 (0,965)	-0,039* (0,068)	-0,023 (0,215)	0,003 (0,891)
<b>BRD</b>	-0,004** (0,039)	-0,002 (0,262)	-0,001 (0,803)	-0,023*** (0,000)	-0,018*** (0,001)	-0,028*** (0,000)
<b>SIZE</b>	0,009*** (0,000)	0,011*** (0,000)	0,003 (0,528)	0,051*** (0,000)	0,056*** (0,000)	0,063*** (0,000)
<b>TAN</b>	-0,018** (0,016)	-0,019*** (0,008)	-0,055** (0,012)	-0,064** (0,011)	-0,064*** (0,009)	-0,026 (0,448)
<b>LIQ</b>	0,005** (0,018)	0,005** (0,025)	0,004 (0,317)	0,013*** (0,009)	0,010* (0,077)	0,016** (0,025)
<b>GRW</b>	0,049*** (0,004)	0,069*** (0,000)	0,092** (0,032)	0,211*** (0,000)	0,131*** (0,009)	0,001 (0,979)
<b>CAPx</b>	0,319*** (0,000)	0,143** (0,041)	0,368*** (0,003)	0,784*** (0,000)	0,964*** (0,000)	0,542** (0,028)
<b>MTB</b>	0,000	0,000	0,000	0,005***	0,004**	0,001

	(0,609)	(0,739)	(0,726)	(0,008)	(0,023)	(0,716)
<b>LEV</b>	-0,022 (0,103)	-0,014 (0,319)	-0,019 (0,349)	-0,111*** (0,001)	-0,079** (0,015)	-0,099** (0,022)
<b>NOL</b>	0,000 (0,940)	-0,002 (0,746)	-0,010 (0,284)	-0,029** (0,030)	-0,019 (0,159)	-0,007 (0,658)
<b>ΔNOL</b>	-0,018*** (0,000)	-0,015*** (0,000)	-0,024*** (0,000)	-0,031*** (0,000)	-0,016** (0,030)	-0,005 (0,498)
<b>MULT</b>	0,001 (0,854)	0,001 (0,898)	0,005 (0,732)	-0,017 (0,329)	-0,034* (0,064)	-0,048** (0,026)
<b>_cons</b>	-0,203*** (0,001)	-0,212*** (0,002)	-0,326** (0,028)	-1,224*** (0,000)	-1,439*** (0,000)	-1,455*** (0,000)
<b>Obs</b>	2171	2171	2138	2650	1725	942
<b>R2 ajust</b>	0,129	0,096	0,004	0,153	0,252	0,332

Nota. Valores p estão entre parênteses  
 \*\*\* p<0,01, \*\* p<0,05, \* p<0,1

Além disso, a literatura sugere que o impacto do CFO em questões fiscais pode ser moderado pela orientação do CEO. Chava e Purnanandam (2010) mostram que a estratégia financeira de uma empresa é muitas vezes um reflexo da visão do CEO, com o CFO atuando mais como um executor das políticas delineadas pelo CEO. Portanto, se o CEO adota uma postura mais conservadora ou agressiva, isso pode reduzir ou ampliar a influência do CFO em medidas como a BTM discricionária, sendo menos significativo o reflexo de seu perfil.

Devido às diferentes escalas das proxies analisadas, como BTM e ETR, torna-se mais complexo comparar a magnitude dos impactos observados utilizando apenas os coeficientes brutos. Com o fim de simplificar a comparação direta dos efeitos nas diferentes proxies, estimamos coeficientes padronizados que estão detalhados nas Tabela 7 e 8 com as estatísticas *t*, oferecendo uma visão mais facilmente comparável entre o impacto do *achievement drive* do CEO e do CFO nas diferentes métricas. Adicionamos a essas mesmas tabelas as métricas AIC, BIC e Log-Likelihood, para fins de comparação da qualidade dos modelos com a estimação por máxima verossimilhança da Tabela 9.

No caso da nossa análise com a variável fCEO, ao calcular o impacto em termos de desvio padrão, descobrimos que fCEO exerce uma influência variada nas proxies de agressividade tributária, conforme indicado pelos coeficientes. Por exemplo, o coeficiente padronizado de fCEO em relação a BTM-Total foi de 0,046, enquanto em relação a ETR foi de 0,032. Isso significa que um aumento de um desvio padrão em fCEO aumenta o BTM em 0,046 desvios-padrões e o ETR em 0,032 desvios-padrões.

Tabela 7

Estimação do efeito da *fWHR* do CEO com coeficientes padronizados

	BTD-Total	BTD-Perm	BTD-Disc	ETR-GAAP	CashETR-3a	CashETR-5a
	(1)	(2)	(3)	(4)	(5)	(6)
<b>fCEO</b>	<b>0,046***</b> (3,141)	<b>0,028*</b> (1,911)	<b>0,030*</b> (1,889)	<b>0,032***</b> (2,594)	<b>0,044***</b> (2,950)	<b>0,055***</b> (2,911)
<b>AGE</b>	0,005 (0,292)	-0,014 (-0,776)	0,029 (1,472)	<b>0,045***</b> (3,337)	0,003 (0,160)	-0,005 (-0,250)
<b>GEN</b>	0,001 (0,078)	-0,009 (-0,874)	-0,001 (-0,215)	-0,007 (-0,627)	0,021 (1,336)	0,022 (1,086)
<b>TEN</b>	<b>0,031*</b> (1,861)	<b>0,030*</b> (1,833)	0,004 (0,249)	<b>0,067***</b> (4,967)	<b>0,104***</b> (6,305)	<b>0,112***</b> (5,189)
<b>INTL</b>	<b>0,037***</b> (3,590)	<b>0,031***</b> (3,255)	<b>0,021**</b> (2,480)	<b>0,022**</b> (2,204)	<b>0,030***</b> (2,668)	<b>0,023*</b> (1,888)
<b>BRD</b>	<b>-0,039**</b> (-2,558)	-0,025 (-1,623)	-0,014 (-1,170)	<b>-0,065***</b> (-4,972)	<b>-0,056***</b> (-3,467)	<b>-0,046**</b> (-2,377)
<b>SIZE</b>	<b>0,202***</b> (9,797)	<b>0,200***</b> (9,618)	<b>0,104***</b> (4,256)	<b>0,227***</b> (15,694)	<b>0,289***</b> (16,781)	<b>0,332***</b> (14,793)
<b>TAN</b>	<b>-0,071*</b> (-1,818)	<b>-0,075***</b> (-2,641)	<b>-0,068*</b> (-1,920)	<b>-0,100***</b> (-5,036)	<b>-0,185***</b> (-6,608)	<b>-0,198***</b> (-6,218)
<b>LIQ</b>	<b>0,082***</b> (4,130)	<b>0,075***</b> (3,545)	<b>0,068**</b> (2,368)	0,024 (1,571)	<b>0,044**</b> (2,340)	0,023 (0,933)
<b>GRW</b>	<b>0,074***</b> (3,229)	<b>0,086***</b> (3,878)	<b>0,044*</b> (1,913)	<b>0,059***</b> (3,975)	<b>0,034*</b> (1,924)	-0,008 (-0,361)
<b>CAPx</b>	<b>0,114***</b> (4,419)	<b>0,059***</b> (2,746)	<b>0,052**</b> (2,503)	<b>0,123***</b> (7,186)	<b>0,174***</b> (8,046)	<b>0,131***</b> (4,855)
<b>MTB</b>	0,020 (1,038)	0,020 (1,066)	-0,003 (-0,145)	<b>0,063***</b> (4,693)	<b>0,036**</b> (1,981)	0,007 (0,296)
<b>LEV</b>	<b>-0,091***</b> (-4,542)	<b>-0,081***</b> (-4,163)	-0,028 (-1,614)	<b>-0,082***</b> (-5,245)	<b>-0,088***</b> (-4,685)	<b>-0,102***</b> (-4,108)
<b>NOL</b>	-0,016 (-1,092)	-0,013 (-0,916)	<b>-0,025**</b> (-2,067)	<b>-0,065***</b> (-5,151)	<b>-0,068***</b> (-4,558)	<b>-0,091***</b> (-4,986)
<b>dNOL</b>	<b>-0,147***</b> (-7,586)	<b>-0,115***</b> (-6,279)	<b>-0,101***</b> (-5,591)	<b>-0,070***</b> (-5,337)	<b>-0,045***</b> (-3,044)	-0,021 (-1,203)
<b>MULT</b>	-0,005 (-0,246)	0,006 (0,303)	0,019 (0,944)	-0,011 (-0,752)	<b>-0,067***</b> (-3,572)	<b>-0,103***</b> (-4,372)
<b>_cons</b>	<b>-0,141***</b> (-2,732)	<b>-0,110*</b> (-1,833)	<b>-0,370***</b> (-2,712)	<b>-1,413***</b> (-8,241)	<b>-1,014***</b> (-6,304)	<b>-0,894***</b> (-5,237)
<b>Obs</b>	5491	5489	5421	6681	4461	2671
<b>R2 ajust.</b>	0,108	0,091	0,013	0,144	0,201	0,247
<b>AIC</b>	-12294,788	-10964,496	-1899,737	2813,062	-177,564	-1124,244
<b>BIC</b>	-11679,977	-10349,719	-1286,120	3459,729	405,121	-635,294
<b>Log.Lik.</b>	6240,394	5575,248	1042,869	-1311,531	179,782	645,122

Nota. Estatísticas t estão entre parênteses

\*\*\* p&lt;0,01, \*\* p&lt;0,05, \* p&lt;0,1

**Tabela 8***Estimação do efeito da fWHR do CFO com coeficientes padronizados*

	BTD-Total	BTD-Perm	BTD-Disc	ETR-GAAP	CashETR-3a	CashETR-5a
	(1)	(2)	(3)	(4)	(5)	(6)
<b>fCFO</b>	<b>0,080***</b> (3,752)	<b>0,073***</b> (3,275)	-0,003 (-0,112)	<b>0,047**</b> (2,451)	<b>0,094***</b> (4,178)	<b>0,124***</b> (4,260)
<b>AGE</b>	0,021 (0,876)	0,016 (0,642)	0,049 (1,305)	0,033 (1,557)	<b>0,046*</b> (1,918)	0,042 (1,332)
<b>GEN</b>	0,010 (0,494)	-0,007 (-0,367)	-0,000 (-0,044)	<b>-0,033*</b> (-1,829)	-0,026 (-1,240)	0,004 (0,137)
<b>BRD</b>	<b>-0,052**</b> (-2,061)	-0,029 (-1,122)	-0,005 (-0,250)	<b>-0,081***</b> (-3,990)	<b>-0,076***</b> (-3,220)	<b>-0,126***</b> (-4,220)
<b>SIZE</b>	<b>0,187***</b> (5,359)	<b>0,197***</b> (5,696)	0,021 (0,630)	<b>0,253***</b> (10,729)	<b>0,344***</b> (11,480)	<b>0,438***</b> (10,898)
<b>TAN</b>	<b>-0,116**</b> (-2,399)	<b>-0,107***</b> (-2,652)	<b>-0,120**</b> (-2,507)	<b>-0,098**</b> (-2,559)	<b>-0,130***</b> (-2,616)	-0,066 (-0,758)
<b>LIQ</b>	<b>0,092**</b> (2,375)	<b>0,091**</b> (2,240)	0,030 (0,999)	<b>0,064***</b> (2,600)	<b>0,057*</b> (1,765)	<b>0,099**</b> (2,237)
<b>GRW</b>	<b>0,111***</b> (2,856)	<b>0,136***</b> (3,526)	<b>0,070**</b> (2,145)	<b>0,107***</b> (4,130)	<b>0,089***</b> (2,624)	0,001 (0,026)
<b>CAPx</b>	<b>0,179***</b> (4,728)	<b>0,070**</b> (2,039)	<b>0,071***</b> (2,927)	<b>0,112***</b> (3,780)	<b>0,159***</b> (4,518)	<b>0,097**</b> (2,192)
<b>MTB</b>	0,012 (0,512)	0,008 (0,333)	0,005 (0,351)	<b>0,062***</b> (2,636)	<b>0,067**</b> (2,280)	0,015 (0,364)
<b>LEV</b>	-0,059 (-1,632)	-0,034 (-0,996)	-0,018 (-0,936)	<b>-0,089***</b> (-3,446)	<b>-0,072**</b> (-2,423)	<b>-0,095**</b> (-2,299)
<b>NOL</b>	0,002 (0,075)	-0,008 (-0,324)	-0,019 (-1,071)	<b>-0,042**</b> (-2,167)	-0,033 (-1,407)	-0,013 (-0,443)
<b>dNOL</b>	<b>-0,186***</b> (-6,672)	<b>-0,132***</b> (-4,980)	<b>-0,083***</b> (-5,686)	<b>-0,071***</b> (-3,487)	<b>-0,050**</b> (-2,169)	-0,018 (-0,678)
<b>MULT</b>	0,005 (0,183)	0,004 (0,128)	0,009 (0,343)	-0,024 (-0,977)	<b>-0,055*</b> (-1,850)	<b>-0,085**</b> (-2,227)
<b>_cons</b>	<b>-0,188***</b> (-2,964)	<b>-0,215***</b> (-3,110)	<b>-0,324**</b> (-2,302)	<b>-1,210***</b> (-5,244)	<b>-1,324***</b> (-6,001)	<b>-1,300***</b> (-4,813)
<b>Obs</b>	2171	2171	2138	2650	1725	942
<b>R2 ajust.</b>	0,136	0,100	0,004	0,153	0,252	0,331
<b>AIC</b>	-5048,091	-4353,303	-28,985	1199,391	-139,886	-404,380
<b>BIC</b>	-4599,029	-3909,925	413,199	1675,889	269,262	-84,272
<b>Log.Lik.</b>	2603,045	2254,651	92,493	-518,695	144,943	268,190

Nota. Estatísticas t estão entre parênteses

\*\*\* p&lt;0,01, \*\* p&lt;0,05, \* p&lt;0,1

### **3.4.3 Testes de robustez**

#### **3.4.3.1. Modelagem multinível**

Isolar o "efeito CEO" nas decisões estratégicas, incluindo a agressividade tributária, representa um desafio metodológico significativo na literatura de contabilidade e finanças. Desde o estudo seminal de Lieberman e O'Connor (1972), que destacou a complexidade em determinar a influência direta dos CEOs sobre o desempenho organizacional, pesquisadores têm buscado métodos mais robustos para separar os efeitos das decisões individuais dos líderes das características inerentes às empresas que gerenciam.

Em um cenário onde a agressividade tributária pode ser influenciada tanto pelas predisposições pessoais do CEO quanto pelo perfil fiscal histórico da empresa, adotar abordagens analíticas que permitam distinguir esses fatores de maneira precisa. Modelos mistos ou hierárquicos, conforme sugerido por estudos recentes (Rönkkö et al., 2023), são ferramentas valiosas para esse fim, pois incorporam efeitos aleatórios no nível da empresa e do diretor, permitindo uma análise mais robusta que reconhece a estrutura multinível dos dados corporativos. Esses modelos acomodam variações tanto dentro das empresas ao longo do tempo quanto entre diferentes empresas, e isolam melhor o impacto no nível das ações do CEO e CFO sobre a agressividade tributária.

Além disso, a questão da endogeneidade é central nessa análise. O desempenho de uma empresa tende a ser influenciado por seu histórico, o que pode introduzir vieses na estimativa do efeito CEO. Rönkkö et al. (2023), baseados em Fitza (2017), argumentam que uma estrutura de autocorrelação de reversão à média é essencial para separar corretamente os efeitos da empresa, do CEO e do tempo sobre o desempenho corporativo.

Nas Tabelas 5 a 8, os testes foram aplicados pelo método dos mínimos quadrados ordinários (MQO). Usando os mesmos controles aplicados aos modelos anteriores, executamos um modelo multinível, adicionando um componente autorregressivo de nível um para considerar a persistência no desempenho da empresa. Assim, o termo de erro segue um padrão AR1 ao longo do tempo, conforme sugerido por Rönkkö et al. (2023). A Tabela 9 apresenta os resultados da estimação por máxima verossimilhança.

**Tabela 9***Estimação do efeito da fWHR com modelagem de três níveis*

	CEO				CFO		
	BTD Total	BTD Disc	ETR GAAP	Cash ETR	BTD Total	BTD Perm	Cash ETR
	(1)	(2)	(3)	(4)	(5)	(6)	(7)
<b>fWHR</b>	<b>0,022**</b> (0,027)	<b>0,038**</b> (0,040)	<b>0,062*</b> (0,088)	<b>0,097**</b> (0,025)	<b>0,039***</b> (0,004)	<b>0,043***</b> (0,002)	<b>0,166***</b> (0,008)
Controles							
CEO	Sim	Sim	Sim	Sim			
CFO					Sim	Sim	Sim
Empresa	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Efeitos fixos Ano e Setor	Sim	Sim	Sim	Sim	Sim	Sim	Sim
<b>_cons</b>	<b>0,284***</b> (0,000)	<b>0,040*</b> (0,070)	<b>0,195***</b> (0,000)	<b>1,207***</b> (0,000)	<b>0,128***</b> (0,000)	<b>0,008</b> (0,804)	<b>1,100***</b> (0,000)
Grupos							
Empresa	864	858	929	798	434	434	406
Diretor	1.087	1.079	1.184	992	530	530	492
Ef. Aleat (var.)							
Empresa	0,0002	0,0000	0,0086	0,0000	0,0006	0,0004	0,0097
Diretor	0,0005	0,0000	0,0089	0,0000	0,0000	0,0000	0,0000
Resíduos	0,0054	0,0399	0,0714	0,0597	0,0047	0,0070	0,0446
AR1	0,2769	0,4024	0,1924	0,8356	0,1277	0,0082	0,8004
Total	0,2830	0,4423	0,2813	0,8953	0,1330	0,0156	0,8547
<b>Obs</b>	5.491	5.421	6.681	4.461	2.174	2.174	1.729
<b>AIC</b>	-12.794	-1.895	2.098	-3.666	-5.129	-4.349	-1.353
<b>BIC</b>	-12.153	-1.255	2.772	-3.058	-4.645	-3.866	-900
<b>Log.Lik.</b>	6.494,37	1044,51	-950,15	1.928,42	2.649,54	2.259,68	759,83

*Nota.* Valores p estão entre parênteses

\*\*\* p<0,01, \*\* p<0,05, \* p<0,1

Na especificação utilizada, conhecida como modelo hierárquico ou multinível (HLM), aplicamos efeitos fixos de ano e de setor, e efeitos aleatórios no nível da empresa e do diretor. O modelo agrupa no nível mais alto as empresas, no nível intermediário o diretor dentro das empresas, e no nível mais baixo a observação individual por ano. A variável de interesse fWHR e as variáveis de controle são incluídas na parte fixa do modelo, no entanto os interceptos no nível da empresa e do diretor são estimados em um componente aleatório.

Para medir a variância atribuída ao nível do diretor, seguimos a metodologia de Rönkkö et al. (2023) e calculamos o “Efeito CEO”, definido como a razão entre a variância do intercepto aleatório do nível do CEO e a soma de todos os componentes de variância. Somente nos Modelos 1 e 3 conseguimos estimar a variância atribuída ao diretor, que correspondem respectivamente a 0,1% e 3,2% da variância total sugere que as variáveis dependentes estão fortemente correlacionadas com o desempenho da empresa no período anterior.

As variáveis de controle mantiveram resultados similares aos encontrados nas Tabelas 5 e 6. Nossa hipótese foi suportada pela maioria dos modelos. No caso do CEO, não encontramos significância na camada permanente da BTM, e no caso do CFO, o teste não confirmou efeito significativo da fWHR no componente discricionário da BTM e nem na medida ETR-GAAP.

### 3.4.3.2. Tempo de mandato e subsequente aumento de agressividade

Na estimação por MQO do efeito da fWHR do CEO, a Tabela 5 revela uma correlação positiva entre o tempo de mandato (variável TEN) e a agressividade tributária, sendo estatisticamente significativa em cinco dos seis modelos estimados. Esse resultado sugere que, todas as demais variáveis constantes, os CEOs que permanecem mais tempo em seus cargos exercem uma influência mais pronunciada sobre as estratégias fiscais da empresa. Esses achados estão em linha com a literatura, que sugere que líderes com maior tempo no cargo podem desenvolver uma maior disposição para implementar estratégias fiscais mais ousadas, provavelmente devido à maior familiaridade com as operações da empresa e com o ambiente regulatório (Jbir et al., 2021).

Com base nesses achados, testamos o efeito diferencial entre os mandatos de CEOs por nível de *achievement drive*. Na Tabela 10, as variáveis CEO (+) e CEO (-) foram criadas para capturar o efeito do tempo de mandato de CEOs divididos pela mediana da fWHR. CEO (+) indica o mandato de CEOs cuja fWHR está acima da mediana, sendo categorizado como 1 no primeiro ano e 2 nos anos subsequentes. Já a variável CEO (-) representa os CEOs com fWHR abaixo da mediana, seguindo a mesma categorização. Nos demais casos, o valor é zero.

**Tabela 10**

*Efeito do tempo de mandato na agressividade tributária*

	(1)	(2)	(3)	(4)	(5)	(6)
	BTD-Total	BTD-Perm	BTD-Disc	ETR-GAAP	CashETR-3a	CashETR-5a
<b>CEO(+)</b>	<b>0,001***</b> (0,000)	<b>0,001**</b> (0,011)	<b>0,002**</b> (0,049)	<b>0,009***</b> (0,000)	<b>0,009***</b> (0,000)	<b>0,008***</b> (0,000)
<b>CEO(-)</b>	0,000 (0,204)	0,000 (0,443)	0,001 (0,334)	<b>0,007***</b> (0,000)	<b>0,005***</b> (0,000)	<b>0,004***</b> (0,000)
<b>BRD</b>	<b>-0,003***</b> (0,004)	<b>-0,002**</b> (0,047)	-0,003 (0,141)	<b>-0,020***</b> (0,000)	<b>-0,015***</b> (0,000)	<b>-0,010***</b> (0,010)
<b>SIZE</b>	<b>0,010***</b> (0,000)	<b>0,011***</b> (0,000)	<b>0,013***</b> (0,000)	<b>0,043***</b> (0,000)	<b>0,044***</b> (0,000)	<b>0,044***</b> (0,000)
<b>TAN</b>	<b>-0,013*</b> (0,069)	<b>-0,016***</b> (0,005)	<b>-0,029*</b> (0,060)	<b>-0,066***</b> (0,000)	<b>-0,106***</b> (0,000)	<b>-0,098***</b> (0,000)
<b>LIQ</b>	<b>0,004***</b> (0,000)	<b>0,004***</b> (0,000)	<b>0,007**</b> (0,016)	0,004 (0,119)	<b>0,007***</b> (0,009)	0,003 (0,268)
<b>GRW</b>	<b>0,029***</b>	<b>0,036***</b>	0,036	<b>0,104***</b>	<b>0,052**</b>	0,005



	(0,002)	(0,000)	(0,114)	(0,000)	(0,026)	(0,843)
<b>CAPx</b>	<b>0,206***</b> (0,000)	<b>0,128***</b> (0,003)	<b>0,231**</b> (0,010)	<b>0,849***</b> (0,000)	<b>1,101***</b> (0,000)	<b>0,759***</b> (0,000)
<b>MTB</b>	0,000 (0,227)	0,000 (0,205)	-0,000 (0,874)	<b>0,004***</b> (0,000)	<b>0,002**</b> (0,029)	0,000 (0,721)
<b>LEV</b>	<b>-0,032***</b> (0,000)	<b>-0,032***</b> (0,000)	-0,023 (0,127)	<b>-0,115***</b> (0,000)	<b>-0,099***</b> (0,000)	<b>-0,094***</b> (0,000)
<b>NOL</b>	-0,003 (0,253)	-0,002 (0,488)	<b>-0,010**</b> (0,045)	<b>-0,046***</b> (0,000)	<b>-0,037***</b> (0,000)	<b>-0,044***</b> (0,000)
<b>ΔNOL</b>	<b>-0,015***</b> (0,000)	<b>-0,013***</b> (0,000)	<b>-0,024***</b> (0,000)	<b>-0,030***</b> (0,000)	<b>-0,015***</b> (0,002)	-0,005 (0,295)
<b>MULT</b>	-0,002 (0,548)	-0,000 (0,956)	0,005 (0,546)	-0,010 (0,314)	<b>-0,035***</b> (0,001)	<b>-0,046***</b> (0,000)
<b>_cons</b>	<b>-0,064***</b> (0,000)	<b>-0,072***</b> (0,000)	<b>-0,093***</b> (0,005)	<b>-0,693***</b> (0,000)	<b>-0,662***</b> (0,000)	<b>-0,639***</b> (0,000)
<b>Obs</b>	5695	5693	5624	6959	4618	2744
<b>R2 ajust.</b>	0,105	0,090	0,012	0,140	0,195	0,246

Nota. Valores p estão entre parênteses

\*\*\* p<0,01, \*\* p<0,05, \* p<0,1

Os coeficientes apresentados indicam uma relação evidente entre a fWHR e a agressividade tributária. O coeficiente positivo e estatisticamente significativo para CEO (+) em todos os seis modelos sugere que, quanto maior o tempo de mandato de um CEO com alta fWHR, maior é a tendência de adoção de estratégias fiscais mais agressivas. Em contraste, para CEOs com fWHR abaixo da mediana, os coeficientes são significativos apenas em três modelos, mas com inclinações menores do que as de CEO (+), o que indica uma tendência menos acentuada de envolvimento em estratégias fiscais ousadas.

### 3.5 Conclusões

Investigamos a relação entre características físicas de CEOs e CFOs, especificamente a relação largura-altura facial (fWHR), que reflete seus níveis de testosterona, e a agressividade tributária em empresas do mercado norte-americano de 1999 a 2019. Os resultados indicam que a fWHR dos gestores, vista como um indicador de *achievement drive*, caracterizado por traços comportamentais como agressividade e dominância, influencia diretamente as estratégias fiscais adotadas pelas corporações.

Nosso primeiro teste, que propôs uma correlação positiva entre a fWHR dos CEOs e a agressividade tributária, foi corroborado pelos dados. CEOs com maior fWHR mostraram-se mais inclinados a adotar estratégias de planejamento tributário mais agressivas, resultando em maiores diferenças entre o lucro contábil e o lucro tributável e menores taxas efetivas de imposto. Adicionalmente, a diferença na magnitude do efeito CEO considerando o tempo de

mandato amplia nossos achados, indicando a fWHR como uma variável moderadora robusta, visto que o tempo de experiência do executivo na mesma empresa pode aumentar sua propensão para práticas menos avessas ao risco. Esse resultado é significativo quando se isolam os CEOs com maior *achievement drive*.

O segundo teste, que analisou isoladamente o *achievement drive* dos CFOs, também confirmou nossa hipótese. CFOs com maior fWHR tendem a influenciar a adoção de estratégias fiscais mais agressivas. Os testes de robustez, realizados por meio de modelos mistos ou hierárquicos, reforçaram a validade dos achados principais, ajudando a isolar os efeitos específicos do CEO e do CFO das características intrínsecas da empresa.

Esses resultados fornecem uma nova perspectiva sobre como fatores comportamentais e biológicos, normalmente não considerados em análises fiscais tradicionais, podem influenciar a agressividade tributária. Sugerimos que a inclusão de variáveis biométricas pode oferecer insights valiosos sobre as interseções entre biologia comportamental, psicologia e finanças corporativas. Futuras pesquisas poderiam ampliar essas descobertas explorando outras medidas biométricas ou psicológicas e aplicando essas análises a diferentes mercados e contextos regulatórios, para avaliar a generalizabilidade dos achados.

## 4 GERENCIAMENTO DE RESULTADOS E O IMPACTO DO *ACHIEVEMENT DRIVE*

### 4.1 Introdução

Este estudo tem como objetivo verificar se o *achievement drive*, refletido na fWHR do CEO, influencia o gerenciamento de resultados por decisões operacionais ou por escolhas contábeis. A hipótese subjacente é que características fisiológicas e comportamentais podem influenciar diretamente as decisões de gestão de lucros, levando os executivos a manipular as demonstrações financeiras para atingir metas de desempenho ou maximizar a remuneração variável.

O gerenciamento de resultados, embora permitido dentro de certos limites contábeis, pode comprometer a transparência financeira e enganar investidores, impactando negativamente a confiança do mercado e a sustentabilidade de longo prazo da empresa (Burgstahler & Dichev, 1997; Dechow et al., 1996). Diversos estudos já identificaram que atributos pessoais dos CEOs, como o excesso de confiança ou tendências narcisistas, podem aumentar a inclinação para o gerenciamento de resultados, principalmente em cenários de pressão para atender às expectativas do mercado (Hsieh et al., 2014; Lin et al., 2020; Resick et al., 2009).

Dada a relevância das características pessoais dos executivos para as decisões corporativas, exploramos neste trabalho a relação entre a fWHR dos CEOs e a propensão para o gerenciamento de resultados, fundamentando-nos na teoria dos escalões superiores (Hambrick & Mason, 1984). Essa teoria postula que as características dos altos executivos, incluindo suas predisposições comportamentais, moldam significativamente as estratégias empresariais e o desempenho organizacional. Ao focar em traços fisiológicos como a fWHR, este estudo procura entender como aspectos inerentes à personalidade e à aparência física dos CEOs podem influenciar práticas contábeis.

Adotamos uma abordagem empírica robusta, utilizando métodos de pareamento e um design de diferenças em diferenças (DiD) para isolar o impacto das características dos CEOs no gerenciamento de resultados, ao mesmo tempo em que controlamos para fatores endógenos e variáveis omitidas. Complementarmente, aplicamos modelagem multinível (*Hierarchical Linear Models* – HLM) para separar o "efeito CEO" das características específicas da empresa, do setor e do período, conforme sugerido na literatura recente (Rönkkö et al., 2023).

Com essa metodologia, buscamos responder à seguinte questão norteadora: a substituição de um CEO por outro com maior *achievement drive* aumenta a agressividade na prática de gerenciamento de resultados? Ao tratar essa questão, visamos contribuir com a

literatura sobre contabilidade comportamental e governança corporativa, explorando a relação entre os traços comportamentais dos líderes e as suas implicações para a gestão financeira.

Uma importante contribuição acadêmica deste estudo está na utilização de inteligência artificial para medir a fWHR, uma variável que reflete predisposições comportamentais associadas ao *achievement drive*, conforme abordado por teorias anteriores na psicologia e endocrinologia (Carre & McCormick, 2008; Lewis et al., 2012). Ao integrar ferramentas avançadas de IA com métodos quantitativos de análise financeira, buscamos não apenas testar hipóteses sobre o impacto das características individuais dos executivos, mas também contribuir para a ampliação do escopo da pesquisa em contabilidade comportamental ao combinar teorias de diferentes campos com a aplicação prática de novas tecnologias analíticas.

## 4.2 Revisão da literatura

O gerenciamento de resultados é uma prática amplamente documentada na literatura contábil, pela qual gestores utilizam discricionariedade nas escolhas contábeis ou decisões operacionais para manipular os relatórios financeiros de suas empresas. Essa manipulação pode ter como objetivo alcançar metas específicas de lucro, influenciar a percepção do mercado sobre o desempenho da empresa, ou atender a expectativas de analistas e investidores (Dechow et al., 1996; Healy & Wahlen, 1999). A prática pode ser realizada de maneira que esteja dentro dos limites da legalidade, mas que ainda assim comprometa a transparência e a qualidade das informações financeiras fornecidas ao mercado, como discutido por Fields et al. (2001).

Existem dois principais tipos de gerenciamento de resultados: o gerenciamento por accruals (*Accrual Earnings Management* - AEM) e o gerenciamento de resultados real (*Real Earnings Management* - REM). O AEM envolve a manipulação de itens contábeis, como a depreciação e a provisão para créditos de liquidação duvidosa, dentro dos limites normativos, permitindo que os gestores ajustem o lucro reportado sem alterar as operações subjacentes da empresa (Dechow et al., 1995; Jones, 1991). Por outro lado, o REM implica em decisões que alteram as atividades operacionais da empresa, como alterar os níveis de produção ou ajustar os gastos com pesquisa e desenvolvimento, para atingir objetivos contábeis específicos (Roychowdhury, 2006; Zang, 2012).

A motivação para o gerenciamento de resultados também está documentada na literatura. Healy e Wahlen (1999) sugerem que os gestores estão frequentemente motivados a gerenciar resultados para aumentar a sua própria remuneração ou garantir a segurança no cargo, quando essas são atreladas ao desempenho financeiro da empresa. Estudos empíricos como os

de Bergstresser e Philippon (2006) e Holthausen et al. (1995) evidenciam que incentivos de compensação baseados em ações são um forte determinante do gerenciamento de resultados.

Outros achados indicam que embora possa ser usada para suavizar ganhos ou ajustar o desempenho percebido em períodos de incerteza, a prática do gerenciamento de resultados geralmente é vista como prejudicial à integridade dos relatórios financeiros e à confiança no mercado de capitais (Graham et al., 2005; Lev, 1989). Por conseguinte, entender os fatores que influenciam o gerenciamento de resultados é valioso para melhorar a qualidade da informação financeira e proteger os interesses dos investidores. As decisões que culminam em práticas contábeis questionáveis frequentemente se alinham com as disposições comportamentais dos gestores, as quais podem ser moldadas por aspectos biológicos e pessoais.

#### ***4.2.1 Teoria dos escalões superiores e gerenciamento de resultados***

A teoria dos escalões superiores (*Upper Echelons Theory* - UET), proposta por Hambrick e Mason (1984), postula que as características pessoais e experiências dos altos executivos, particularmente dos CEOs, moldam de maneira significativa as decisões estratégicas da empresa. De acordo com essa teoria, os executivos não são tomadores de decisão totalmente racionais; em vez disso, suas decisões são influenciadas por suas características demográficas, traços comportamentais e experiências anteriores. Essas características pessoais dos executivos, como idade, gênero, experiência e formação educacional, afetam suas percepções e interpretações de situações complexas, levando a decisões que, muitas vezes, podem refletir seus próprios interesses ou vieses pessoais (Finkelstein et al., 2009, Hambrick, 2007).

Aplicando a UET ao contexto do gerenciamento de resultados, é razoável supor que as características do CEO influenciem as práticas contábeis e a transparência financeira da empresa. CEOs com um perfil mais agressivo ou com menor aversão ao risco podem estar mais inclinados a adotar práticas contábeis oportunistas para melhorar os resultados financeiros percebidos e, assim, alcançar metas de desempenho ou expectativas de mercado. Estudos como os de Ali e Zhang (2015) demonstram que CEOs tendem a gerenciar os lucros de forma mais agressiva no início de seus mandatos, quando a pressão para provar suas habilidades é mais intensa. Similarmente, a experiência e o histórico do CEO podem influenciar a escolha entre gerenciamento de resultados por escolhas contábeis e gerenciamento real, refletindo seu perfil em termos de manipulação financeira (Putra & Setiawan, 2024).

#### 4.2.2 *Achievement drive, testosterona e estrutura facial*

Uma característica particular que tem ganhado atenção na literatura é o *achievement drive*, ou impulso de conquista, frequentemente associado a altos níveis de testosterona e biomarcadores que refletem o efeito organizacional desse hormônio, como a proporção largura-altura facial (fWHR). Gestores com um forte impulso de conquista tendem a focar em resultados de curto prazo e objetivos financeiros, muitas vezes às custas de considerações éticas ou de longo prazo (He et al., 2019; Jia et al., 2014).

Estudos demonstram uma relação consistente entre altos níveis de testosterona e comportamentos mais agressivos e competitivos, incluindo contextos que envolvem a tomada de decisões financeiras e estratégicas. Durante a puberdade, a testosterona exerce um papel crítico na reorganização de regiões cerebrais associadas à propensão ao risco, como a amígdala e o córtex pré-frontal (Herbert, 2018; Steinberg, 2008). Esse processo hormonal influencia não apenas o comportamento, mas também o desenvolvimento físico, incluindo a estrutura facial (Verdonck et al. 1999). A proporção largura-altura facial tem sido amplamente utilizada como uma proxy para essas predisposições comportamentais, com pesquisas indicando que homens com fWHR mais elevada exibem comportamentos mais dominantes e competitivos (Carré & McCormick, 2008; Lefevre et al., 2013).

Com base nesses achados, CEOs com maior fWHR, refletindo níveis mais elevados de testosterona, são frequentemente associados a comportamentos mais agressivos, tanto na gestão de suas equipes quanto na forma como manipulam resultados financeiros. A busca por sucesso de curto prazo, impulsionada por um forte *achievement drive*, pode levar esses executivos a adotarem práticas contábeis mais arriscadas, visando maximizar o desempenho financeiro imediato, mesmo que isso comprometa a sustentabilidade de longo prazo.

Sob essa perspectiva, formulamos a hipótese de que CEOs com características indicadoras de alta testosterona estão mais inclinados a adotar estratégias gerenciais mais agressivas, em termos de gerenciamento de resultados. Essa hipótese será testada por meio da interação entre períodos e grupos de controle e de tratamento, que nos permitirá avaliar o impacto dessas características na prática de gerenciamento de resultados antes e depois da transição do CEO.

### 4.3 Desenho da pesquisa

#### 4.3.1 Construção da amostra

Utilizamos dados de empresas da base Compustat North America e informações de executivos da base Execucomp, abrangendo o período de 1999 a 2019. A amostra inicial incluía 1.301 empresas distintas e 10.563 observações de dados financeiros, bem como 1.383 CEOs distintos. A partir dessa amostra, empresas do setor financeiro (SIC entre 6000 e 6999) foram removidas devido às características contábeis específicas dessas instituições, além de observações com dados faltantes. Exluímos, em seguida, empresas onde não houve troca de CEO durante o período de estudo, e casos em que o mandato do CEO foi inferior a três anos. Após essas exclusões, a amostra final consistiu em 116 empresas distintas, com um total de 231 CEOs diferentes e 653 observações empresa-ano.

#### 4.3.2 Variáveis dependentes

Para analisar o gerenciamento de resultados, estimamos duas proxies distintas que refletem o gerenciamento por escolhas contábeis e o gerenciamento de resultados por decisões operacionais. A primeira proxy, baseada em accruals discricionários (*discretionary accruals* – DACC), segue o modelo de Jones modificado por Dechow et al. (1995), amplamente utilizado na literatura para detectar práticas de manipulação contábil.

Inicialmente, calculamos os accruals totais ( $TA_{it}$ ) para cada empresa-ano, seguindo a Equação (1), em que:  $\Delta AC_{it}$  é a variação do ativo circulante da empresa  $i$  no período de  $t-1$  para o período  $t$ ;  $\Delta DISP_{it}$  é a variação nas disponibilidades no mesmo intervalo de tempo;  $\Delta PC_{it}$  é a variação no passivo circulante;  $\Delta EMP_{it}$ , a variação dos empréstimos e financiamentos de curto prazo; e  $DP_{it}$ , referente às despesas de depreciação e amortização no período  $t$ .

$$TA_{it} = (\Delta AC_{it} - \Delta DISP_{it}) - (\Delta PC_{it} - \Delta EMP_{it}) - DP_{it} \quad (1)$$

Conceitualmente, essa medida possui um componente não discricionário estimado pela Equação (2). O componente discricionário (DACC), foco da análise, é a diferença entre os accruals totais e a parte não discricionária, refletida nos resíduos da regressão. O modelo foi estimado por ano e código SIC de dois dígitos, excluídos os setores com menos de dez observações em um mesmo ano, onde  $A_{i,t-1}$  são os ativos totais no início do período,  $\Delta Sales_{it}$  são as mudanças nas receitas operacionais,  $\Delta REC_{it}$  é a variação das contas a receber, e  $PPE_{it}$  é o ativo imobilizado.

$$\frac{TA_{it}}{A_{i,t-1}} = \beta_0 + \beta_1 \frac{1}{A_{i,t-1}} + \beta_2 \frac{\Delta Sales_{it} + \Delta REC_{it}}{A_{i,t-1}} + \beta_3 \frac{PPE_{it}}{A_{i,t-1}} + \varepsilon_{it} \quad (2)$$

Quanto ao gerenciamento de resultados por decisões operacionais (REM), este foi medido utilizando o modelo de Roychowdhury (2006). As Equações (3), (4) e (5) foram usadas para estimar, em cada combinação setor-ano, os níveis normais do fluxo de caixa operacional (CFO), custos de produção (PROD) e despesas discricionárias (DISEXP). Os níveis anormais (ABN\_CFO, ABN\_PROD e ABN\_DISEXP) são fornecidos pelos resíduos da regressão, isto é, valor real observado menos o valor normal estimado para cada setor-ano. Assumimos que desvios elevados indicam práticas de gerenciamento de resultados por decisões operacionais.

$$\frac{CFO_{it}}{A_{i,t-1}} = \beta_0 + \beta_1 \left( \frac{1}{A_{i,t-1}} \right) + \beta_2 \left( \frac{Sales_{it}}{A_{i,t-1}} \right) + \beta_3 \left( \frac{\Delta Sales_{it}}{A_{i,t-1}} \right) + \varepsilon_{it} \quad (3)$$

A Equação (3) estima o fluxo de caixa operacional ( $CFO_{it}$ ) normal como uma função linear das vendas e das variações nas vendas durante o período analisado. Práticas de manipulação de vendas, como a concessão de descontos de preços maiores ou condições de crédito mais flexíveis, podem resultar em um  $CFO$  anormalmente baixo e custos de produção mais elevados do que o esperado. O resíduo da equação ( $\varepsilon_{it}$ ) reflete esse  $CFO$  anormal, servindo como uma proxy para identificar um tipo de gerenciamento de resultados por decisões operacionais. Todas as variáveis foram escaladas pelos ativos totais da empresa no período anterior.

$$\frac{PROD_{it}}{A_{i,t-1}} = \beta_0 + \beta_1 \left( \frac{1}{A_{i,t-1}} \right) + \beta_2 \left( \frac{Sales_{it}}{A_{i,t-1}} \right) + \beta_3 \left( \frac{\Delta Sales_{it}}{A_{i,t-1}} \right) + \beta_4 \left( \frac{\Delta Sales_{i,t-1}}{A_{i,t-1}} \right) + \varepsilon_{it} \quad (4)$$

A Equação (4) estima os custos de produção normais ( $PROD_{it}$ ) como uma função linear das vendas líquidas de um período e suas variações em dois períodos consecutivos. Enquanto  $\Delta Sales_{it}$  captura a variação entre  $t-1$  e  $t$ ,  $\Delta Sales_{i,t-1}$  captura entre  $t-2$  e  $t-1$ .

Quando as empresas aumentam a produção para reduzir o custo unitário dos produtos vendidos, o fluxo de caixa operacional pode ser inferior ao normal, considerando os níveis de vendas reais. Para medir esses custos, utiliza-se como variável dependente os custos de produção, que são definidos pela soma dos custos dos produtos vendidos e das variações de estoques da empresa no período. A receita líquida de vendas ( $Sales_{it}$ ) e as variações de receita entre períodos consecutivos ( $\Delta Sales_{it}$  e  $\Delta Sales_{i,t-1}$ ) são usadas como preditores dos custos normais de produção. O resíduo da equação ( $\varepsilon_{it}$ ) representa os custos de produção anormais.



$$\frac{DISEXP_{it}}{A_{i,t-1}} = \beta_0 + \beta_1 \left( \frac{1}{A_{i,t-1}} \right) + \beta_2 \left( \frac{Sales_{it}}{A_{i,t-1}} \right) + \varepsilon_{it} \quad (5)$$

A Equação (5) é utilizada para estimar os níveis normais de despesas discricionárias ( $DISEXP_{it}$ ), que são expressos como uma função linear das vendas líquidas ( $Sales_{it}$ ) e dos ativos totais da empresa no período anterior. A manipulação de resultados pode ocorrer quando os gestores reduzem essas despesas no curto prazo, com o objetivo de aumentar temporariamente a lucratividade. Essas reduções são mais prováveis quando as despesas não geram receitas imediatas. A variável dependente DISEXP é definida como a soma das despesas gerais, administrativas e de vendas. O resíduo da regressão indica o nível anormal de despesas discricionárias, funcionando como uma proxy para a manipulação de resultados por meio da redução dessas despesas.

Os valores anormais para o fluxo de caixa operacional (ABN\_CFO), custos de produção (ABN\_PROD) e despesas discricionárias (ABN\_DISEXP) foram calculados como a diferença entre os valores observados e os valores normais estimados a partir das Equações (3), (4) e (5), respectivamente. Para visualizar o comportamento da medida de manipulação de resultados capturada por REM, os valores anormais de fluxo de caixa e despesas discricionárias foram multiplicados por -1, ou seja,  $ABN\_CFO = (-1) \times$  fluxo de caixa anormal e  $ABN\_DISEXP = (-1) \times$  despesas discricionárias anormais. Já os custos de produção anormais (ABN\_PROD) permanecem como originalmente calculados, pois aumentam com a superprodução das empresas. A partir dessas medidas, construímos a variável REM, somando os componentes ABN\_CFO, ABN\_PROD e ABN\_DISEXP, que reflete o gerenciamento agregado.

### 4.3.3 Grupos de Controle e Tratamento

Estimamos o efeito da fWHR do CEO no gerenciamento de resultados dividindo a amostra em dois períodos. Criamos a variável *POST* para distinguir os períodos antes e após a rotatividade de CEO. O período  $t-1$  refere-se ao período de no mínimo três anos anteriores, e  $t$ , ao período de no mínimo três anos posteriores. Por exemplo, se um diretor assume a função de CEO em 2007, o período anterior a esse ano está em  $t-1$ , se o mandato do CEO anterior for de no mínimo três anos. O período  $t$  compreende de 2007 em diante, enquanto o CEO recém-empossado se mantiver na função.

A metodologia empregada nesta pesquisa compara dois grupos de CEO. Definimos os grupos de tratamento e controle pela variável *TREAT*, que indica se o CEO possui um fWHR no extremo superior da distribuição. O grupo de tratamento é composto por CEOs com fWHR nos três decis superiores, enquanto o grupo de controle inclui aqueles nos três decis inferiores

da distribuição de fWHR. Observações de CEOs cujas fWHR não se enquadram nesses critérios foram excluídas da análise.

#### 4.3.4 *Pareamento*

A confiabilidade da comparação entre os grupos depende, em grande parte, da semelhança entre eles em termos de características observáveis e não observáveis que podem influenciar o gerenciamento de resultados. Considerando que existem diferenças potenciais entre os grupos, uma simples comparação direta poderia resultar em vieses, refletindo nas variáveis de impacto fatores que já existiam antes da troca do CEO. Caso os CEOs com fWHR elevada apresentem as mesmas características, as diferenças observadas poderiam estar relacionadas a esses fatores, e não diretamente à fWHR.

Seguindo Rosenbaum e Rubin (1983), e Shipman et al. (2017), utilizamos o método *Propensity Score Matching* (PSM) com o fim de mitigar o problema apresentado no parágrafo anterior. Identificamos no período pré-troca de CEO ( $POST=0$ ), para cada CEO do grupo de tratamento, um correspondente no grupo de controle que tenha características semelhantes, como idade e tempo no cargo, além de similaridades no nível da empresa, como grau de endividamento e desempenho financeiro.

Estimamos a probabilidade de uma empresa pertencer ao grupo de tratamento por meio de um modelo *logit*. O pareamento foi realizado utilizando um *caliper* de 0,01, para que a diferença máxima aceitável entre pares seja controlada, e a técnica do vizinho mais próximo (*nearest neighbour 1*) foi aplicada para selecionar as observações mais comparáveis. Em seguida, mantivemos para o nosso modelo apenas as correspondências que estão dentro do *common support*, estendendo-as à amostra pós-transição do CEO.

#### 4.3.5 *Modelo de efeitos fixos*

Para examinar o impacto do *achievement drive* do CEO no gerenciamento de resultados, empregamos um modelo de diferenças em diferenças (DiD). Nessa especificação, nossa variável dependente (GR) representa o gerenciamento de resultados, medido por meio de accruals discricionários (DACC) ou decisões operacionais (REM). As variáveis de interesse incluem *TREAT*, que indica se o CEO pertence ao grupo de tratamento (com alta fWHR), e *POST*, que marca o período após a mudança de CEO. A interação entre essas variáveis ( $TREAT \times POST$ ) nos permite identificar o efeito diferencial do novo executivo no gerenciamento de resultados.

Nossa equação de regressão pode ser representada por

$$GR_{it} = \beta_0 + \beta_1 TREAT_{it} + \beta_2 POST_{it} + \beta_3 TREAT_{it} \times POST_{it} + \beta_n \sum X_{it} + \theta_t + \tau_i + \varepsilon_{it} \quad (6)$$

onde  $GR_{it}$  representa nossas proxies de gerenciamento de resultados da empresa  $i$  no ano  $t$ , testadas separadamente; o coeficiente  $\beta_1$  captura o efeito da variável de tratamento (fWHR extrema do CEO) da firma  $i$  no ano  $t$  na variável dependente; o coeficiente  $\beta_2$  captura o efeito da variável  $POST$  (período após troca do CEO);  $\beta_3$  captura o efeito da interação (nosso resultado de interesse);  $X_{it}$  representa um vetor de variáveis de controle no nível do CEO e da firma;  $\theta_t$  são os efeitos fixos do tempo (ano);  $\tau_i$  representa o efeito fixo do setor e  $\varepsilon_{it}$  o termo de erro robusto à heteroscedasticidade.

Incluimos uma série de variáveis de controle. No nível do CEO, consideramos: idade (AGE), uma vez que CEOs mais velhos podem demonstrar maior aversão ao risco; sexo (GEN), visto que homens e mulheres podem diferir em suas abordagens à tomada de risco no contexto corporativo; tempo de mandato como CEO (TEN), uma vez que gestores com maior tempo no cargo tendem a estar mais familiarizados com as práticas de gerenciamento de resultados, o que pode influenciar suas decisões ao longo do tempo; e as compensações totais anormais (SAL), pois incentivos financeiros além do padrão podem motivar os CEOs a adotar práticas de gerenciamento de resultados com o objetivo de maximizar o desempenho da empresa.

No nível da empresa, controlamos pela alavancagem financeira (LEV), pois empresas com alta alavancagem frequentemente enfrentam pressões de *covenants* financeiros, criando incentivos para gerenciar os resultados com o intuito de cumprir as expectativas financeiras; indicadores como o ROA (*Return on Assets*) e o EBITDA (*Earnings Before Interests, Taxes, Depreciation and Amortization Expenses*), que medem o desempenho operacional e também podem influenciar a disposição dos gestores em manipular resultados. A Tabela 11 apresenta as definições e referências das variáveis de controle utilizadas no estudo.

**Tabela 11**  
*Variáveis de controle*

Variável	Sigla	Estudos anteriores
Idade do CEO	AGE	(Al-Begali & Phua, 2023; Davis & Garcia-Cestona, 2023)
Sexo do CEO	GEN	(Putra & Setiawan, 2024; Peni & Vähämaa, 2010)

Tempo de mandato do CEO em anos	TEN	(Ali & Zhang, 2015; Hazarika et al., 2012)
Valor anormal das compensações totais do CEO	SAL	(Bergstresser & Philippon, 2006; Carter et al., 2009; Cheng & Warfield, 2005)
Alavancagem financeira	LEV	(Jaggi & Lee, 2002)
Retorno sobre ativos	ROA	(Martinez, 2008)
Lucro antes de juros, impostos, depreciação e amortização	EBTD	(Martinez, 2008; Stubben, 2010)
Prejuízo líquido	LOSS	(Peni & Vähämaa, 2010; Ye et al., 2010)

Incluimos efeitos fixos de ano e setor (SIC de dois dígitos) para mitigar o impacto de características invariantes ao longo do tempo e entre diferentes setores. Todas as regressões são estimadas com erros padrão robustos visando fornecer estimativas mais confiáveis. De acordo com nossa hipótese, esperamos encontrar um coeficiente positivo para a interação *TREATxPOST*, indicando um aumento no gerenciamento de resultados associado a um maior *achievement drive* do CEO em comparação com o CEO anterior.

#### 4.3.6 Modelo multinível ou hierárquico

Para fins de robustez, usamos um modelo multinível ou hierárquico para capturar as variações nas decisões gerenciais com relação ao nível individual do CEO, no contexto da empresa e período. O modelo hierárquico linear (HLM) permite distinguir entre as influências pessoais do CEO e as características estruturais da empresa, acomodando as especificidades de cada nível e proporcionando uma análise mais robusta que reflete a complexidade dos dados corporativos (Rönkkö et al., 2023).

Seguindo Hair e Fávero (2019), verificamos primeiramente a existência de variabilidade de nossas variáveis dependentes estimando um modelo nulo considerando três níveis: observação anual, CEO e empresa (Equação 7).

$$GR_{tij} = \beta_{ij} + \varepsilon_{tij} \quad (7)$$

onde  $t$  representa o nível 1, isto é, a observação individual com efeitos fixos de ano;  $i$  representa o nível 2 (CEO); e  $j$  representa o nível 3 (empresa).

Confirmada a variabilidade e a existência de uma estrutura aninhada, estimamos um modelo de tendência linear com os interceptos aleatórios (Monsalves et al., 2020). As inclinações das variáveis independentes foram estimadas na parte fixa da equação, bem como as *dummies* de setor e de ano. A Equação 8 expressa o modelo final em que adaptamos a notação utilizada por Mo et al. (2023).

$$GR_{tij} = \gamma_{000} + \gamma_{0ij} + \gamma_{00j} + \gamma_{1ij}TREAT_{tij} + \gamma_{2ij}POST_{tij} + \gamma_{3ij}TREAT_{tij} \times POST_{tij} + \gamma_n \sum X_{tij} + \theta_t + \tau_i + \underbrace{\mu_{0ij} + \tau_{00j}} + \varepsilon_{tij} \quad (8)$$

onde  $\gamma_{000}$  é o intercepto da parte fixa, a média geral no nível da observação individual (ano);  $\gamma_{0ij}$  e  $\gamma_{00j}$  são os interceptos nos níveis de grupos (nesta ordem: CEO e empresa);  $\gamma_{3ij}$  captura o efeito da interação entre grupo de tratamento e período (nosso resultado de interesse);  $X_{tij}$  representa um vetor de variáveis de controle no nível do CEO e da firma;  $\theta_t$  e  $\tau_i$  são os efeitos fixos de ano e de setor. Os três termos na parte destacada representam os componentes aleatórios, com as três fontes de variância:  $\mu_{0ij}$  = efeitos aleatórios do CEO;  $\tau_{00j}$  = efeitos aleatórios da empresa e  $\varepsilon_{tij}$  = termo de erro.

## 4.4 Principais resultados empíricos

### 4.4.1 Estatística descritiva

Iniciamos a análise dos resultados empíricos com uma visão geral das estatísticas descritivas das variáveis utilizadas em nosso estudo, conforme mostrado na Tabela 12. As variáveis dependentes apresentam médias de 0,048 e 0,042, respectivamente, para gerenciamento via ajustes contábeis e gerenciamento através de decisões operacionais. A variável de interesse, proxy que representa o impulso de conquista dos CEOs, tem uma média de 2,24 e um desvio padrão de 0,166, valores próximos a estudos recentes.

Entre os controles do CEO, a idade média é de 56 anos, e o tempo médio de mandato é de 5,15 anos. A compensação total anormal mostra uma média negativa, indicando que a maioria dos CEOs na amostra pode ter recebido menos do que o esperado, considerando a distribuição normal de compensação.

**Tabela 12***Resumo estatístico e matriz de correlação**Painel A – Resumo estatístico das variáveis contínuas*

Variável	N	Média	DP	p25	p50	p75
Variáveis dependentes						
<b>DACC</b>	635	0,048	0,059	0,013	0,029	0,059
<b>REM</b>	554	0,042	0,305	-0,106	0,033	0,175
Variável de interesse						
<b>fWHR</b>	647	2,240	0,166	2,123	2,235	2,339
Controles do CEO						
<b>AGE</b>	635	56	7	51	56	61
<b>TEN</b>	648	5,151	6,557	1,735	2,997	5,778
<b>SAL</b>	647	-41,82	1947,59	-249,45	-150,79	-47,65
Controles da empresa						
<b>LEV</b>	651	0,234	0,193	0,072	0,226	0,340
<b>ROA</b>	653	0,037	0,116	0,007	0,049	0,088
<b>EBTD</b>	653	0,143	0,105	0,090	0,132	0,187

*Painel B - Matriz de correlação e estatística VIF (Variance Inflation Factor)*

	VIF	DACC	fWHR	AGE	TEN	SAL	LEV	ROA
<b>DACC</b>		1,00						
<b>fWHR</b>	1,05	-0,01	1,00					
<b>AGE</b>	1,32	<b>-0,11</b>	-0,01	1,00				
<b>TEN</b>	1,28	0,03	<b>-0,02</b>	<b>0,43</b>	1,00			
<b>SAL</b>	1,03	<b>0,08</b>	-0,01	0,00	0,01	1,00		
<b>LEV</b>	1,05	<b>-0,10</b>	<b>-0,06</b>	<b>-0,02</b>	<b>-0,07</b>	<b>-0,02</b>	1,00	
<b>ROA</b>	1,99	<b>-0,10</b>	<b>0,03</b>	<b>0,03</b>	<b>0,03</b>	<b>0,06</b>	<b>-0,04</b>	1,00
<b>EBTD</b>	1,97	<b>-0,04</b>	0,01	-0,01	0,00	<b>-0,04</b>	<b>0,03</b>	<b>0,36</b>

Ao vincular essas características ao tratamento de rotatividade de CEOs, identificamos que houve 94 trocas de CEO após a exclusão de dados faltantes e restrições aplicadas, como setores financeiros, e mandatos com duração inferior a 3 anos. Dessas 94 trocas válidas em nossa amostra, a análise revela diferentes padrões de substituição: 31 trocas envolveram a substituição de um CEO com baixa fWHR por outro também com baixa, 14 substituições foram de um CEO com baixa fWHR por um com alta, 19 trocas foram de um CEO com alto fWHR por um com baixa, e 30 substituições mantiveram CEOs com alta fWHR.

Esses padrões de substituição permitem uma análise diferenciada sobre como o tempo de mandato dos CEOs varia em função da rotatividade e do perfil de fWHR. A Tabela 13 resume as estatísticas descritivas para o tempo de mandato dos CEOs por período (pré e pós-transição). Observa-se que, em média, o tempo de mandato no grupo total é de 12,53 anos no período pré-transição e aumenta ligeiramente para 12,75 anos no pós-transição. Quando analisamos por

grupos de controle e tratamento, vemos que CEOs no grupo de controle (baixa fWHR) tendem a ter mandatos um pouco mais curtos, com média de 12,12 anos no pré-transição e 12,61 anos no pós-transição. Já os CEOs no grupo de tratamento apresentam um tempo de mandato ligeiramente superior no período pós-transição.

**Tabela 13**

*Resumo estatístico da fWHR e do mandato do CEO*

Amostra	Obs	n	fWHR		Tempo de mandato	
			Média	DP	Média	DP
<b>Total</b>						
Total	647	230	2,24	0,16	12,53	4,20
Controle	215	80	2,06	0,08	12,12	4,68
Tratamento	207	70	2,43	0,09	12,75	4,06
<b>Pré-transição</b>						
Total	274	118	2,23	0,17	12,12	4,68
Controle	92	41	2,05	0,09	11,46	4,64
Tratamento	82	33	2,42	0,09	12,49	3,80
<b>Pós-transição</b>						
Total	373	127	2,25	0,16	12,75	4,06
Controle	123	41	2,06	0,06	12,61	4,67
Tratamento	125	43	2,43	0,09	12,93	4,23

*Nota.* Alguns CEOs compõem tanto a amostra pré-transição quanto pós-transição em momentos distintos, por essa razão, os valores de n (CEOs únicos) por período somados não correspondem ao da amostra total.

#### 4.4.2 Testes univariados

Os testes univariados apresentados na Tabela 14 oferecem uma análise inicial da diferença entre os dois grupos em relação às variáveis dependentes e de controle. Observamos que a variável DACC (valor absoluto dos accruals discricionários estimados) apresenta uma média menor no grupo de tratamento, com uma diferença estatisticamente significativa ao nível de 5%. Esse resultado sugere que CEOs com a fWHR mais elevada (mais avessos ao risco) estariam associados a menores níveis de gerenciamento de resultados via accruals, o que pode refletir um comportamento mais conservador ou um enfoque em outras formas de manipulação de resultados.

No que diz respeito à variável REM, a Tabela 14 revela uma média negativa para o grupo de controle e positiva para o grupo de tratamento, diferença estatisticamente significativa ao nível de 1%. Esse contraste acentuado sugere que CEOs com maior fWHR podem estar mais inclinados a gerenciar resultados por meio de decisões reais de negócios, como manipulação de produção ou despesas discricionárias, em vez de ajustes contábeis. Estudos anteriores, como

Cohen e Zarowin (2010), indicam que o *real earnings management* pode ser uma escolha preferencial em ambientes onde há maior escrutínio regulatório ou quando o gerenciamento via accruals se torna mais arriscado.

**Tabela 14**

*Comparação entre grupos de controle e de tratamento*

	Controle		Tratamento		t-stat
	Obs	Média	Obs	Média	
<b>DACC</b>	211	0,052	201	0,042	<b>1,75**</b>
<b>REM</b>	174	-0,024	179	0,085	<b>-3,31***</b>
<b>AGE</b>	330	56,4	345	55,7	1,22
<b>GEN</b>	337	0,950	346	0,962	-0,82
<b>TEN</b>	337	4,81	343	5,42	-1,28
<b>SAL</b>	337	156,14	346	-396,17	<b>2,26**</b>
<b>LEV</b>	337	0,280	343	0,238	<b>2,59***</b>
<b>ROA</b>	337	0,046	342	0,024	<b>2,30**</b>
<b>EBTD</b>	296	0,144	308	0,125	<b>1,95**</b>
<b>LOSS</b>	337	0,214	346	0,234	-0,64

Analisando os controles demográficos e financeiros, notamos diferenças significativas em algumas variáveis. Por exemplo, a diferença entre os valores da variável SAL indicam que CEOs no grupo de tratamento receberam remunerações totais menos anormais em comparação com o grupo de controle. Isso pode ser indicativo de políticas de compensação mais restritivas ou de um foco em incentivos não monetários para um grande número de CEOs. No nível da empresa, a alavancagem (LEV) apresenta uma diferença estatisticamente significativa a 1% entre os grupos, possivelmente refletindo a capacidade ou disposição de CEOs com maior *achievement drive* em utilizar menos dívida como parte de suas estratégias de financiamento.

A Tabela 15 compara as médias das variáveis antes e depois da rotatividade de CEO. Observamos que a idade do CEO diminui significativamente após a rotatividade, com uma diferença altamente significativa ao nível de 1%. Conforme as tendências apontadas por Li et al. (2017), podemos sugerir que empresas tendem a substituir CEOs mais velhos por candidatos mais jovens, potencialmente buscando novos estilos de liderança, reestruturação ou diferentes abordagens estratégicas. Além disso, o tempo de mandato (variável TEN) também apresenta uma queda relevante após a troca de CEO, com diferença novamente significativa, possivelmente para mitigar práticas não capturadas por esta análise, que se consolidaram ao longo de longos períodos de liderança.



**Tabela 15***Comparação entre períodos pré e pós rotatividade de CEO*

	Pré-transição		Pós-transição		t-stat
	Obs	Média	Obs	Média	
<b>DACC</b>	166	0,044	246	0,049	-1,00
<b>REM</b>	141	0,042	212	0,025	0,49
<b>AGE</b>	291	59,5	384	53,5	<b>11,81***</b>
<b>GEN</b>	297	0,970	386	0,946	<b>1,52*</b>
<b>TEN</b>	294	8,45	386	2,58	<b>13,74***</b>
<b>SAL</b>	297	-230,02	386	-41,81	-0,76
<b>LEV</b>	295	0,261	385	0,257	0,19
<b>ROA</b>	294	0,038	385	0,033	0,46
<b>EBTD</b>	264	0,145	340	0,126	<b>1,96**</b>
<b>LOSS</b>	297	0,185	386	0,254	<b>-2,14**</b>

#### 4.4.3 Diferenças em diferenças com pareamento

Os testes univariados revelaram algumas diferenças relevantes entre os grupos de controle e tratamento, bem como na comparação entre os períodos antes e depois da troca de CEOs. Contudo, ainda não conseguimos demonstrar uma associação estatisticamente significativa entre a substituição de CEOs e as mudanças nas estratégias gerenciais. Essa ausência de uma associação clara pode ser explicada pela complexidade inerente aos fatores que influenciam o comportamento gerencial.

Devido à natureza multidimensional dos fatores que interagem simultaneamente como características do CEO, condições da empresa e influências externas, o uso de testes multivariados torna-se essencial. Visando lidar com preocupações de endogeneidade, realizamos uma análise de diferenças em diferenças (Roberts & Whited, 2013). Examinamos as mudanças nas práticas de gerenciamento de resultados em torno de substituições de CEOs, focando na alteração do nível de impulso de conquista, medido pela fWHR.

Destacamos que a escolha de uma variável contínua como a fWHR impõe limitações para validar nossa hipótese ao considerar mudanças mínimas nessa métrica. Pequenas alterações na fWHR podem não capturar completamente a variação comportamental do CEO. Para contornar essa limitação, optamos por utilizar uma variável de tratamento (*TREAT*) que considera os extremos da distribuição da fWHR, além da implementação de um pareamento por pontuação de propensão.

O pareamento por pontuação de propensão (*propensity score matching*) é reconhecido como uma técnica eficaz para criar grupos de controle e tratamento comparáveis, sobretudo em estudos que lidam com variações naturais e diferenças não aleatórias entre observações (Rosenbaum & Rubin, 1983; Shipman et al., 2017). Em nossa análise, o pareamento permite

isolar o impacto do *achievement drive* do CEO, minimizando a influência de variáveis de confusão. Combinar empresas com características semelhantes antes da transição do CEO, contribui para que as diferenças observadas nos resultados pós-transição possam ser atribuídas mais diretamente à mudança no CEO e não a outros fatores. Este procedimento segue recomendações de estudos anteriores que enfatizam a importância do pareamento para melhorar a validade causal das estimativas de diferença em diferenças (Abadie & Imbens, 2006; Stuart, 2010).

**Tabela 16***Diferenças em diferenças após pareamento*

	(1) DACC	(2) REM
<b>POST</b>	-0,009 (0,357)	<b>-0,286***</b> (0,000)
<b>TREAT</b>	<b>-0,019***</b> (0,009)	0,051 (0,335)
<b>POST * TREAT</b>	<b>0,034***</b> (0,005)	<b>0,237***</b> (0,002)
<b>AGE</b>	<b>-0,002***</b> (0,001)	<b>0,007**</b> (0,019)
<b>GEN</b>	<b>-0,077***</b> (0,002)	<b>0,141***</b> (0,005)
<b>TEN</b>	<b>0,002***</b> (0,001)	<b>-0,011***</b> (0,007)
<b>SAL</b>	<b>0,000**</b> (0,013)	<b>-0,000***</b> (0,005)
<b>LEV</b>	<b>-0,035**</b> (0,027)	<b>0,187*</b> (0,099)
<b>ROA</b>	-0,021 (0,629)	-0,022 (0,942)
<b>EBTD</b>	<b>0,118***</b> (0,002)	<b>-0,638**</b> (0,048)
<b>LOSS</b>	<b>0,021**</b> (0,015)	-0,042 (0,398)
<b>_cons</b>	<b>0,215***</b> (0,000)	<b>-0,339*</b> (0,063)
<b>Obs</b>	378	395
<b>R2 ajust.</b>	0,375	0,373
<b>AIC</b>	-1195,640	-12,790
<b>BIC</b>	-1148,421	34,926
<b>Log-likelihood</b>	609,820	18,395

Nota. Valores p estão entre parênteses


\*\*\* p<0,01, \*\* p<0,05, \* p<0,1

A Tabela 16 apresenta os resultados da estimação por MQO após o pareamento, utilizando a interação entre o período pós-substituição de CEO e a variável de tratamento, que identifica CEOs nos extremos superiores e inferiores da distribuição de fWHR. Observa-se que a interação  $POST \times TREAT$  é significativa e positiva tanto para o gerenciamento de resultados por accruals discricionários (DACC) quanto para o gerenciamento de resultados por decisões operacionais (REM). Esses achados sinalizam que mudanças significativas no *achievement drive* do CEO, refletidas em um aumento de fWHR, estão associadas a um aumento no uso de técnicas de gerenciamento de resultados.

Os gráficos subsequentes (Figura 3) fornecem uma representação visual dessas dinâmicas. Para DACC, observa-se uma tendência ascendente no grupo de tratamento após a transição do CEO, contrastando com uma tendência descendente no grupo de controle. Essa divergência indica que empresas que substituem um CEO por outro com maior fWHR tendem a intensificar o uso de accruals discricionários para manipulação de resultados. Por outro lado, para REM, enquanto ambos os grupos exibem uma tendência de redução, o grupo de tratamento demonstra uma redução menos acentuada, sugerindo que o impacto do *achievement drive* é mais pronunciado na manipulação de resultados por accruals do que por decisões operacionais.

**Figura 4**

*Efeitos marginais da relação tratamento x período*



No entanto, se considerarmos os desvios-padrões de DACC e REM (0,059 e 0,305, respectivamente) e padronizarmos os coeficientes para fins de comparação, observamos que o efeito médio padronizado do tratamento no gerenciamento de resultados é de 0,576 para DACC e 0,777 para REM. Isso indica que, embora ambos os tipos de gerenciamento de resultados

sejam significativamente impactados, o efeito sobre REM é mais forte. Em ambos os casos, as variáveis são influenciadas em mais de meio desvio-padrão, destacando o impacto substancial da fWHR no comportamento gerencial analisado. Estes resultados estão alinhados com estudos anteriores que mostram que características individuais dos CEOs podem ter um impacto significativo nas decisões estratégicas da empresa, incluindo práticas de gerenciamento de resultados (Graham et al., 2013; Malmendier & Tate, 2005).

A idade do CEO mostrou significância estatística em ambas as formas de gerenciamento de resultados, com uma correlação negativa em DACC (gerenciamento por accruals discricionários) e positiva em REM (gerenciamento por decisões operacionais). Isso sugere que, quanto mais velho o CEO, menor a prática de DACC e maior a prática de REM. Esses resultados estão em linha com os achados de Davis & Garcia-Cestona (2023), que observaram que a idade influencia o estilo de gerenciamento de resultados, com executivos mais velhos mostrando menor propensão a escolhas contábeis agressivas. No entanto, nossos achados divergem dos resultados de Al-Begali e Phua (2023), que, ao examinar o mercado asiático, encontraram coeficientes com sinais opostos aos dos nossos testes.

Em relação ao sexo, nossa amostra indica que CEOs do sexo feminino são mais propensas a praticar o gerenciamento por accruals, enquanto os CEOs do sexo masculino tendem a adotar mais o gerenciamento por decisões operacionais. Esse comportamento é consistente com um dos achados de Putra e Setiawan (2024), que descobriram que executivas mulheres são menos propensas a manipular resultados operacionais, possivelmente devido a uma menor propensão ao risco e uma maior preocupação com a reputação e a ética. No entanto, nosso modelo (1) mostrou divergência com esse mesmo estudo e também em relação aos achados de Peni e Vähämaa (2010).

O tempo de mandato do CEO também apresenta uma diferença de sinal conforme o tipo de gerenciamento de resultados, com CEOs com mais tempo no cargo praticando mais gerenciamento por accruals e menos por REM. A análise do tempo de mandato é complexa, pois as práticas de gerenciamento de resultados podem variar ao longo do mandato do CEO. CEOs em início ou fim de mandato podem enfrentar pressões para manipular resultados com o fim de apresentar números consistentes (Hazarika et al., 2012). Nossos resultados são compatíveis com alguns achados de Ali e Zhang (2015), que identificaram uma relação significativa e complexa entre o tempo de mandato e a superdeclaração de lucros.

As compensações anormais não mostraram um efeito significativo nas práticas de gerenciamento de resultados em nossa amostra, diferentemente de estudos anteriores. Carter et al. (2009) encontraram uma relação positiva entre gerenciamento de resultados e bônus

executivos nos EUA, enquanto outros estudos, como Bergstresser e Philippon (2006) e Cheng e Warfield (2005), mostram que a remuneração baseada em incentivos de ações está associada ao uso de accruals discricionários. Embora a compensação variável seja uma ferramenta importante de governança corporativa (Goergen e Renneboog, 2011), nossos resultados indicam que, neste contexto, a influência das compensações anormais foi limitada.

Empresas mais alavancadas mostraram tendência a menor uso de accruals e maior uso de gerenciamento por decisões operacionais. Esse comportamento pode ser interpretado como uma tentativa das empresas em atender às expectativas dos credores, minimizando práticas contábeis arriscadas e adotando estratégias operacionais. Nossos resultados corroboram estudos como o de Jaggi e Lee (2002), que sugerem que altos níveis de endividamento influenciam as escolhas de manipulação dos lucros.

Utilizamos o ROA e o EBITDA para controlar o desempenho econômico e operacional, considerando que empresas com maior rentabilidade apresentam práticas distintas de gerenciamento de resultados (Martinez, 2008). Embora o ROA não tenha mostrado significância em nossos testes, o EBITDA apresentou-se significativo em ambos os modelos, com um efeito positivo no gerenciamento por accruals e negativo no gerenciamento por decisões operacionais. Isso sugere que empresas com um maior potencial de geração de caixa podem estar mais inclinadas a manipular resultados contábeis (DACC), enquanto evitam manipulações operacionais, confirmando o papel do EBITDA em diferenciar o desempenho real das práticas de gerenciamento (Stubben, 2010).

A variável dummy LOSS, que indica se a empresa teve prejuízo no ano, apresentou significância apenas no gerenciamento por accruals (DACC). Peni e Vähämaa (2010) também encontraram que empresas com prejuízo tendem a ser mais propensas ao gerenciamento por accruals. Nesse contexto, LEV e LOSS atuam como proxies para a condição financeira da empresa, conforme discutido por DeAngelo et al. (1994), que observaram que empresas em dificuldades financeiras podem ter fortes incentivos para utilizar accruals gerenciando o lucro.

#### **4.4.4 Teste de robustez**

Verificamos a robustez dos resultados por modelos multiníveis, apresentados na Tabela 17. Tal modelagem é adequada neste contexto para capturar variações que ocorrem tanto entre quanto dentro das empresas ao longo do tempo, fornecendo uma análise isolada dos efeitos da mudança de CEO. Conforme evidenciado, a interação entre as variáveis POST e TREAT é positiva e estatisticamente significativa para ambas as medidas de gerenciamento de resultados, suportando nossa hipótese.

**Tabela 17**  
*Estimação com modelagem multinível*

	(1) DACC	(2) REM
<b>POST</b>	-0,008 (0,534)	<b>-0,122**</b> (0,018)
<b>TREAT</b>	<b>-0,019*</b> (0,050)	0,041 (0,430)
<b>POST * TREAT</b>	<b>0,028*</b> (0,060)	<b>0,152**</b> (0,014)
<b>AGE</b>	<b>-0,002***</b> (0,002)	<b>0,006*</b> (0,074)
<b>GEN</b>	<b>-0,081***</b> (0,000)	-0,069 (0,557)
<b>TEN</b>	<b>0,001**</b> (0,011)	-0,003 (0,355)
<b>SAL</b>	<b>0,000**</b> (0,044)	-0,000 (0,684)
<b>LEV</b>	-0,026 (0,220)	-0,063 (0,499)
<b>ROA</b>	-0,017 (0,786)	-0,068 (0,593)
<b>EBTD</b>	<b>0,105**</b> (0,026)	<b>-0,569***</b> (0,000)
<b>LOSS</b>	<b>0,021**</b> (0,023)	-0,000 (0,988)
<b>_cons <math>\gamma_{000}</math></b>	<b>0,313***</b> (0,000)	-0,301 (0,269)
<b>Grupos</b>		
	<b>Empresas</b>	66
	<b>CEO</b>	101
<b>Efeitos Aleatórios (variância)</b>		
<b>_cons (Empresa) <math>\tau_{00j}</math></b>	0,0000	0,052
<b>_cons (CEO) <math>\mu_{0ij}</math></b>	0,0002	0,014
<b>Residual <math>\varepsilon_{tij}</math></b>	0,0021	0,010
<b>Total <math>\mu_{0ij} + \tau_{00j} + \varepsilon_{tij}</math></b>	0,0023	0,076
<b>Obs</b>	378	395
<b>AIC</b>	-1135,967	-325,947
<b>BIC</b>	-958,897	-146,897
<b>Log-likelihood</b>	612,984	207,974

Nota. Valores p estão entre parênteses  
\*\*\* p<0,01, \*\* p<0,05, \* p<0,1

Considerando os coeficientes dos modelos (1) e (2) da Tabela 17, os impactos médios do tratamento no gerenciamento de resultados são de 0,028 e 0,152. Ambos são menores do que os da Tabela 16, tanto na magnitude da inclinação, quanto na significância estatística. Em comparação com a modelagem multinível, a estimação por MQO pode estar superestimando o efeito estudado, conforme sugere Rönkkö et al. (2023). Em relação aos efeitos aleatórios, da variância total ( $\mu_{0ij} + \tau_{00j} + \varepsilon_{tij}$ ) podemos atribuir 8,8% ao efeito CEO ( $\mu_{0ij}$ ) no modelo (1) e 18,8% no modelo (2), valores compatíveis com esse mesmo estudo.

Ademais, comparando os valores dos critérios de ajuste AIC, BIC e log-likelihood por variável dependente, podemos considerar que as variáveis utilizadas contribuíram para um melhor ajuste na estimação de DACC (modelo 1 da Tabela 16). Comparando a análise por modelagem, o uso de modelo hierárquico apresentou melhor ajuste geral.

## 4.5 Testes adicionais

### 4.5.1 Desagregação das decisões operacionais

Na primeira análise adicional, separamos o gerenciamento por decisões operacionais pelos três componentes: ABN\_CFO, ABN\_PROD e ABN\_DISEXP. Cada uma dessas variáveis captura um aspecto diferente do gerenciamento de resultados, permitindo uma análise mais granular e específica dos mecanismos pelos quais o fWHR do CEO pode influenciar o comportamento gerencial.

A Tabela 18 mostra que, enquanto o nível anormal de fluxo de caixa operacional (ABN\_CFO) não apresenta uma interação significativa com a variável POST x TREAT, o nível anormal de custos de produção (ABN\_PROD) e o nível anormal de despesas de vendas, gerais e administrativas (ABN\_DISEXP) demonstram um coeficiente positivo e estatisticamente significativo para a interação, sugerindo que CEOs com maior fWHR tendem a aumentar os custos de produção e reduzir despesas discricionárias anormalmente, possivelmente para manipular os resultados financeiros de maneira a manter uma imagem de eficiência e controle operacional.

Seguindo os estudos de Cohen e Zarowin (2010) e Zang (2012), construímos duas medidas alternativas REM1 e REM2. Enquanto REM1 é a soma de ABN\_CFO e ABN\_DISEXP, REM2 é a soma de ABN\_PROD e ABN\_DISEXP. As duas medidas foram impactadas positivamente em nossa análise da Tabela 18.

**Tabela 18**  
*Medidas alternativas de REM*

	(1)	(2)	(3)	(4)	(5)
	ABN_CFO	ABN_PROD	ABN_DISEXP	REM1	REM2
POST	-0,016 (0,133)	<b>-0,122***</b> (0,000)	<b>-0,136***</b> (0,000)	<b>-0,152***</b> (0,000)	<b>-0,265***</b> (0,000)
TREAT	<b>0,028***</b> (0,005)	0,000 (0,988)	0,013 (0,678)	0,041 (0,212)	0,020 (0,687)
POST * TREAT	0,018 (0,219)	<b>0,125***</b> (0,000)	<b>0,090**</b> (0,033)	<b>0,107**</b> (0,021)	<b>0,212***</b> (0,002)
AGE	<b>0,001***</b> (0,004)	0,002 (0,173)	<b>0,003*</b> (0,050)	<b>0,004***</b> (0,009)	<b>0,005*</b> (0,050)
GEN	<b>0,024**</b> (0,021)	<b>0,040*</b> (0,067)	<b>0,064**</b> (0,022)	<b>0,088***</b> (0,003)	<b>0,123**</b> (0,010)
TEN	<b>-0,001***</b> (0,008)	<b>-0,004**</b> (0,012)	<b>-0,006***</b> (0,004)	<b>-0,007***</b> (0,001)	<b>-0,009**</b> (0,018)
SAL	<b>-0,000*</b> (0,098)	<b>-0,000**</b> (0,030)	<b>-0,000***</b> (0,000)	<b>-0,000***</b> (0,000)	<b>-0,000***</b> (0,004)
LEV	0,018 (0,425)	-0,012 (0,800)	<b>0,138**</b> (0,026)	<b>0,156**</b> (0,021)	0,167 (0,112)
ROA	-0,069 (0,147)	-0,074 (0,519)	-0,016 (0,914)	-0,085 (0,600)	0,013 (0,964)
EBTD	<b>-0,293***</b> (0,000)	<b>-0,274*</b> (0,060)	-0,004 (0,977)	<b>-0,297*</b> (0,080)	-0,350 (0,216)
LOSS	0,007 (0,584)	-0,012 (0,559)	-0,028 (0,322)	-0,022 (0,486)	-0,050 (0,264)
_cons	<b>-0,069*</b> (0,063)	-0,029 (0,703)	<b>-0,195*</b> (0,058)	<b>-0,263**</b> (0,022)	-0,272 (0,103)
Obs	459	394	459	459	394
R2 ajust.	0,501	0,294	0,387	0,423	0,346

Nota. Valores p estão entre parênteses

\*\*\* p<0,01, \*\* p<0,05, \* p<0,1

#### 4.5.2 Reavaliação dos períodos de mudança de CEO

Na segunda análise adicional, ajustamos os períodos de observação para capturar mais precisamente os efeitos da transição de CEO sobre o gerenciamento de resultados. Em vez de realizar uma comparação simples das médias antes e após a mudança de CEO, desagregamos os anos do mandato. Nos modelos 1 e 2 da Tabela 19, definimos T-1 como o mandato anterior (grupo de referência nos dois modelos), T como o primeiro ano do novo CEO, e T+1 como o segundo ano em diante.



**Tabela 19**  
*Diferenças em diferenças com períodos alternativos*

	Período T-1 a T+1		Período T-2 a T+1	
	(1) DACC	(2) REM	(3) DACC	(4) REM
<b>T-1</b>			-0,010 (0,220)	<b>-0,107**</b> (0,015)
<b>T</b>	0,024 (0,203)	<b>-0,252***</b> (0,008)	0,020 (0,310)	<b>-0,293***</b> (0,002)
<b>T+1</b>	-0,017 (0,117)	<b>-0,295***</b> (0,000)	<b>-0,021*</b> (0,064)	<b>-0,328***</b> (0,000)
<b>TREAT</b>	<b>-0,018**</b> (0,016)	0,050 (0,341)	<b>-0,027***</b> (0,003)	0,037 (0,545)
<b>T-1 * TREAT</b>			<b>0,026*</b> (0,072)	0,054 (0,505)
<b>T * TREAT</b>	-0,002 (0,916)	0,147 (0,168)	0,010 (0,676)	0,159 (0,164)
<b>T+1 * TREAT</b>	<b>0,043***</b> (0,002)	<b>0,266***</b> (0,001)	<b>0,052***</b> (0,000)	<b>0,274***</b> (0,002)
<b>AGE</b>	<b>-0,002***</b> (0,001)	<b>0,007***</b> (0,008)	<b>-0,002***</b> (0,001)	<b>0,007**</b> (0,012)
<b>GEN</b>	<b>-0,064***</b> (0,004)	<b>0,155***</b> (0,003)	<b>-0,065***</b> (0,004)	<b>0,159***</b> (0,003)
<b>TEN</b>	<b>0,002***</b> (0,001)	<b>-0,011***</b> (0,006)	<b>0,002***</b> (0,001)	<b>-0,011***</b> (0,006)
<b>SAL</b>	<b>0,000**</b> (0,028)	<b>-0,000***</b> (0,007)	<b>0,000**</b> (0,029)	<b>-0,000***</b> (0,006)
<b>LEV</b>	<b>-0,029*</b> (0,061)	<b>0,185*</b> (0,096)	<b>-0,031*</b> (0,053)	0,163 (0,151)
<b>ROA</b>	-0,002 (0,966)	-0,031 (0,490)	0,014 (0,771)	-0,040 (0,900)
<b>EBTD</b>	<b>0,102**</b> (0,015)	<b>-0,637***</b> (0,009)	<b>0,089**</b> (0,039)	<b>-0,662**</b> (0,043)
<b>LOSS</b>	<b>0,020**</b> (0,025)	-0,043 (0,304)	<b>0,021**</b> (0,020)	-0,043 (0,384)
<b>_cons</b>	<b>0,199***</b> (0,000)	<b>-0,373**</b> (0,034)	<b>0,205***</b> (0,000)	<b>-0,334*</b> (0,068)
<b>Obs</b>	379	395	378	394
<b>R2 ajust.</b>	0,384	0,374	0,385	0,377

Nota. Valores p estão entre parênteses

\*\*\* p<0,01, \*\* p<0,05, \* p<0,1


No modelo 1 da Tabela 19, a variável isolada referente ao primeiro ano de mandato não é significativa para DACC, sugerindo que, no primeiro ano após a substituição do CEO, não há evidências estatísticas de um ajuste imediato nas práticas de gerenciamento de resultados via accruals discricionários. No entanto, no modelo (2), T é significativo a 1% e negativo para REM, o que sugere a possibilidade de práticas de *big bath accounting*, em que novos CEOs optam por reconhecer perdas no primeiro ano para ajustar as expectativas e permitir uma

melhoria de desempenho nos anos seguintes. Isso está de acordo com a literatura que discute a propensão de novos CEOs a "limpar o balanço" logo após a transição.

Contudo, quando observamos a interação de T com a variável TREAT, notamos que T X TREAT não é significativo em nenhum dos modelos. Por outro lado, T+1 X TREAT é significativo e positivo em todos os modelos, sugerindo que, embora o primeiro ano não traga mudanças significativas no gerenciamento de resultados para CEOs com maior fWHR, o impacto se torna evidente na média do restante do mandato, com um aumento nas práticas de gerenciamento de resultados tanto via DACC quanto por REM. Isso indica que CEOs com maior fWHR, após um período de adaptação, podem adotar uma postura mais agressiva a partir do segundo ano de mandato. A Figura 5 representa graficamente os efeitos marginais dessa interação.

**Figura 5**

*Efeitos marginais da relação tratamento x períodos t-1 a t+1*




Adicionalmente, ampliamos a análise para incluir o período T-2 a T+1, que considera separadamente o último ano do mandato anterior (T-1), o primeiro ano do novo mandato (T) e o segundo ano em diante do novo mandato (T+1), em comparação ao período de referência (modelos 3 e 4). Os resultados sugerem que CEOs recém-empossados ajustam as práticas de gerenciamento de resultados, possivelmente para estabelecer uma base de desempenho a ser melhorada nos anos subsequentes, ou por assumirem após rotatividade forçada do CEO anterior por práticas agressivas na gestão dos ganhos. A Figura 6 representa graficamente essa dinâmica.

A significância da interação T-1 X TREAT no modelo 3 para DACC é um ponto importante a ser destacado. Esse resultado sugere que, no último ano de mandato do CEO anterior, houve uma prática agressiva de gerenciamento de resultados via accruals discricionários, o que pode ter contribuído para sua substituição. Esse achado está alinhado com estudos como Hazarika et al. (2012), que indicam que altos níveis de gerenciamento de resultados podem ser um fator determinante para a rotatividade forçada de CEOs.

**Figura 6**

*Efeitos marginais da relação tratamento x períodos t-1 a t+2*



#### 4.5.3 Teste com isolamento de accruals positivos e negativos

Usando os mesmos períodos da análise anterior, a Tabela 20 apresenta os resultados do gerenciamento por accruals discricionários, segmentando o gerenciamento agressivo para aumentar os ganhos e o gerenciamento para reduzi-los. Nos dois primeiros modelos, que consideram todo o período pré-transição como referência, encontramos significância estatística apenas no primeiro ano do novo CEO no gerenciamento que reduz os ganhos (DACC negativo), indicando novamente um comportamento compatível com o *Big Bath Accounting*, em que novos CEOs, sobretudo aqueles com maior *achievement drive*, preferem reconhecer perdas maiores no início de seus mandatos, preparando o terreno para melhores resultados futuros. Essa prática, caracterizada pela redução dos lucros no primeiro ano, é confirmada para o grupo de tratamento, composto por CEOs com maior fWHR.

**Tabela 20***Efeito diferencial no aumento e na redução dos resultados*

	<b>Período T<sub>-1</sub> a T<sub>+1</sub></b>		<b>Período T<sub>-2</sub> a T<sub>+1</sub></b>	
	(1) DACC(+)	(2) DACC(-)	(3) DACC(+)	(4) DACC(-)
<b>T<sub>-1</sub></b>			<b>-0,033***</b> (0,007)	0,009 (0,429)
<b>T</b>	0,036 (0,472)	-0,032 (0,204)	0,024 (0,612)	-0,028 (0,289)
<b>T<sub>+1</sub></b>	<b>-0,054**</b> (0,022)	0,011 (0,420)	<b>-0,064***</b> (0,003)	0,015 (0,294)
<b>Treat</b>	-0,005 (0,730)	0,006 (0,549)	<b>-0,039**</b> (0,021)	0,011 (0,341)
<b>T<sub>-1</sub> * Treat</b>			<b>0,101***</b> (0,008)	-0,013 (0,424)
<b>T * Treat</b>	-0,037 (0,499)	<b>0,051**</b> (0,038)	0,002 (0,966)	<b>0,048*</b> (0,086)
<b>T<sub>+1</sub> * Treat</b>	0,033 (0,234)	0,017 (0,200)	<b>0,066**</b> (0,023)	0,013 (0,430)
<b>AGE</b>	<b>-0,002***</b> (0,002)	-0,001 (0,544)	<b>-0,002***</b> (0,007)	-0,001 (0,590)
<b>GEN</b>	0,000 (.)	<b>0,049**</b> (0,030)	0,000 (.)	<b>0,050**</b> (0,031)
<b>TEN</b>	0,005 (0,352)	-0,001 (0,932)	0,007 (0,263)	-0,001 (0,922)
<b>SAL</b>	<b>-0,000**</b> (0,031)	<b>0,000***</b> (0,001)	<b>-0,000**</b> (0,026)	<b>0,000***</b> (0,001)
<b>LEV</b>	0,017 (0,596)	<b>-0,037*</b> (0,087)	-0,014 (0,715)	<b>-0,037*</b> (0,090)
<b>ROA</b>	-0,079 (0,482)	-0,088 (0,192)	-0,013 (0,902)	-0,094 (0,179)
<b>EBTD</b>	0,138 (0,159)	<b>0,199***</b> (0,000)	0,068 (0,421)	<b>0,206***</b> (0,000)
<b>LOSS</b>	-0,011 (0,480)	-0,012 (0,401)	0,000 (0,987)	-0,011 (0,470)
<b>_cons</b>	<b>0,156***</b> (0,000)	0,022 (0,742)	<b>0,163***</b> (0,000)	0,014 (0,841)
<b>Obs</b>	125	225	125	224
<b>R2 ajust.</b>	0,457	0,606	0,519	0,602

Nota. Valores p estão entre parênteses

\*\*\* p&lt;0,01, \*\* p&lt;0,05, \* p&lt;0,1

Nos modelos 3 e 4, que consideram como referência o período pré-transição exceto último ano, revelam-se novos padrões. O último ano de mandato do CEO anterior no grupo de tratamento mostra um gerenciamento para aumentar os lucros, sugerindo que esses CEOs

podem estar adotando práticas agressivas para inflar resultados no final de seus mandatos, o que pode justificar uma substituição forçada. No período pós-transição (T+1), observamos que os novos CEOs do grupo de tratamento voltam a praticar gerenciamento agressivo para aumentar os lucros, com um coeficiente estatisticamente significativo.

O primeiro ano do novo mandato se destaca como o único período em que o CEO adota a prática de suavização de ganhos, com coeficiente estatisticamente significativo. Esse padrão evidencia que CEOs com maior *achievement drive* tendem a ser mais inclinados a utilizar práticas de gerenciamento de resultados, tanto para reduzir quanto para aumentar os ganhos. Nossa hipótese é suportada, com esses CEOs mostrando-se particularmente agressivos em momentos específicos, comportamento que já foi amplamente documentado na literatura contábil, especialmente quando há incentivos ou pressões para ajustar as expectativas de desempenho da empresa (Cohen & Zarowin, 2010; Degeorge et al., 1999; Graham et al., 2005; Healy & Wahlen, 1999).

#### 4.6 Conclusões

Nossas análises empíricas confirmaram a hipótese de que CEOs com uma maior fWHR estão mais inclinados a práticas de gerenciamento de resultados. Contribuímos para a literatura ao demonstrar a significância estatística de aspectos comportamentais e de personalidade, que tradicionalmente são coletadas de forma subjetiva, como confundidoras em testes de efeitos causais. Essa abordagem permite uma compreensão mais profunda das dinâmicas organizacionais e da influência dos traços pessoais dos CEOs nas práticas de gerenciamento de resultados, algo que ainda é pouco explorado na literatura contábil.

Os testes adicionais reforçaram a presença de práticas já documentadas na literatura, como o *big bath accounting* e a suavização de ganhos, frequentemente associadas a objetivos estratégicos de manipulação contábil. Nossos resultados indicaram que CEOs com maior *achievement drive* têm maior tendência a recorrer a essas práticas, sugerindo que a inclusão dessa característica comportamental em estudos sobre gerenciamento de resultados pode aumentar a precisão dos modelos analíticos.

Verificamos que o *achievement drive* dos CEOs é uma variável relevante para as investigações em práticas de gerenciamento de resultados, destacando-se como um elemento que influencia significativamente as decisões contábeis. A inclusão do *achievement drive* como variável de controle em futuros estudos pode esclarecer melhor os mecanismos subjacentes ao comportamento gerencial, auxiliando na compreensão das razões pelas quais certos executivos adotam práticas agressivas ou conservadoras.

Nosso estudo apresenta algumas limitações. Primeiramente, a análise foi restrita ao mercado norte-americano, o que limita a generalização dos resultados para outros contextos culturais e econômicos. Futuras pesquisas poderiam ampliar o escopo deste estudo, incluindo uma comparação com economias emergentes, para verificar se os mesmos padrões de comportamento são observáveis.

Sugestões para futuras pesquisas incluem a exploração do impacto de outros traços comportamentais dos CEOs, além da expansão da amostra para utilização de fotos dos diretores financeiros. Essas ampliações ajudariam a fornecer uma visão mais completa do impacto das características individuais dos líderes empresariais nas práticas contábeis globais. Além disso, seria interessante investigar como diferentes estruturas de governança corporativa podem moderar a relação entre as características do CEO e o gerenciamento de resultados, o que poderia revelar novos insights sobre a eficácia dos mecanismos de controle e monitoramento dentro das empresas.

## **5 CONSIDERAÇÕES FINAIS**

Nesta tese, buscamos oferecer uma visão inovadora sobre o impacto do big data e das tecnologias emergentes no campo da contabilidade comportamental. Nossa pesquisa focou na análise da relação entre a razão largura/altura facial de CEOs e a prática de gerenciamento de resultados, abordando a influência da testosterona e, conseqüentemente, de características comportamentais como agressividade e dominância. Utilizando metodologias de análise robustas, como modelos multiníveis para isolar o "efeito CEO", os testes empíricos contribuem para novas direções para a pesquisa comportamental em finanças e contabilidade.

A análise crítica das metodologias tradicionais revelou que muitos estudos falham ao não incorporar variáveis subjetivas essenciais para compreender melhor a influência dos executivos nos resultados organizacionais. Embora o uso de atributos diretamente observáveis, como idade, salário e sexo seja comum, tais abordagens frequentemente ignoram mecanismos intermediários que causam de forma mais significativa o efeito estudado. Nosso estudo demonstra que, embora seja possível realizar análises preditivas sem recorrer a atributos subjetivos, a inclusão desses fatores aumenta significativamente a capacidade explicativa dos modelos, oferecendo respostas mais robustas à pergunta do "porquê" dos comportamentos observados.

A distinção entre gerenciamento de resultados e planejamento tributário agressivo justifica a análise desses temas em artigos separados, dada a diferença em suas fundamentações

teóricas e implicações práticas. O gerenciamento de resultados manipula a percepção dos stakeholders sobre a performance financeira da empresa, impactando diretamente a confiança dos investidores e as cotações de ações. O planejamento tributário agressivo, focado na minimização da carga tributária através de estratégias legais, afeta diretamente a liquidez e os lucros reportados da empresa. Separar essas práticas permite uma análise mais profunda das diferentes motivações, riscos e impactos econômicos associados a cada uma, oferecendo insights valiosos tanto para acadêmicos quanto para formuladores de políticas.

No decorrer deste estudo, algumas limitações metodológicas foram identificadas, o que impõe cautela ao interpretar os resultados e sugere novas direções para pesquisas futuras. Em primeiro lugar, a análise limitou-se ao mercado norte-americano, o que restringe a generalização dos achados para outras regiões com diferentes práticas de governança corporativa e culturais. Além disso, a coleta de dados foi realizada utilizando-se apenas uma ferramenta de IA, a visão computacional. Embora essa escolha tenha permitido uma análise profunda de traços faciais, ela pode ser enriquecida ao capturar outras variáveis comportamentais que não são detectáveis por essa tecnologia.

Outro aspecto limitante refere-se à amostra desbalanceada no primeiro estudo empírico de fotos de CFOs em comparação com o número de imagens disponíveis para CEOs. Algumas empresas em nossa amostra apresentaram séries temporais interrompidas de dados visuais, o que afeta a robustez da análise longitudinal. Curiosamente, observamos que quanto mais recente o período de análise, maior a disponibilidade de fotos variadas, o que é positivo, mas também traz um novo desafio: a possibilidade de que muitas dessas imagens tenham sido ajustadas por softwares como o Photoshop, distorcendo a precisão dos cálculos de fWHR. Para mitigar esse viés, sugerimos que futuras pesquisas busquem um número cada vez maior de fotos por executivo e utilizem algoritmos aprimorados para identificar e excluir imagens manipuladas. O contínuo avanço do big data e o uso cada vez mais disseminado de redes sociais corporativas oferecem uma oportunidade para acessar dados visuais em larga escala, desde que essas limitações sejam consideradas.

Além disso, o número crescente de procedimentos estéticos entre executivos pode influenciar os resultados, uma vez que tais intervenções alteram a fWHR, mas não os traços comportamentais subjacentes. Alterações artificiais no rosto, portanto, representam um viés significativo ao estudar a relação entre morfologia facial e comportamento. Da mesma forma, o uso crescente de terapias hormonais, como a aplicação discricionária de testosterona por parte de CEOs, pode enviesar essa relação. Embora a testosterona natural influencie a fWHR ao longo do desenvolvimento do indivíduo, os aumentos temporários induzidos por suplementação

hormonal afetam diretamente o comportamento sem necessariamente alterar a morfologia facial de forma duradoura.

Em termos de pesquisa futura, sugerimos expandir o escopo para incluir outras regiões geográficas, além de combinar diferentes ferramentas de IA, como reconhecimento de padrões de fala em vídeos e áudios, para objetivar variáveis que, até então, foram estudadas de forma subjetiva. O uso crescente de redes sociais pelas empresas abre novas perspectivas para a coleta de dados em ambientes naturais, permitindo a observação de dimensões até então negligenciadas no comportamento executivo. A análise de sinais corporais e padrões de comunicação não verbal capturados por vídeo poderia proporcionar insights adicionais, especialmente quando combinado com teorias da psicologia e comportamento organizacional.



## REFERÊNCIAS

- Abadie, A., & Imbens, G. W. (2006). Large sample properties of matching estimators for average treatment effects. *Econometrica*, 74(1), 235-267.  
<https://doi.org/10.1111/j.1468-0262.2006.00655.x>
- Adams, R. B., & Funk, P. (2012). Beyond the glass ceiling: Does gender matter? *Management Science*, 58(2), 219-235. <https://doi.org/10.1287/mnsc.1110.1452>
- Ahmed, S., Sihvonen, J., & Vähämaa, S. (2019). CEO facial masculinity and bank risk-taking. *Personality and Individual Differences*, 138, 133-139.  
<https://doi.org/10.1016/j.paid.2018.09.029>
- Al-Begali, S. A. A., & Phua, L. K. (2023). Accruals, real earnings management, and CEO demographic attributes in emerging markets: Does concentration of family ownership count? *Cogent Business & Management*, 10(2).  
<https://doi.org/10.1080/23311975.2023.2239979>
- Ali, A., & Zhang, W. (2015). CEO tenure and earnings management. *Journal of Accounting and Economics*, 59(1), 60-79. <https://doi.org/10.1016/j.jacceco.2014.11.004>
- Amanatkar, H. R., Chibnall, J., Seo, B., Manepalli, J., & Grossberg, G. (2014). Impact of exogenous testosterone on mood: a systematic review and meta-analysis of randomized placebo-controlled trials. *Annals of Clinical Psychiatry*, 26(1), 19-32.
- André, C. Phrenology and the Rwandan Genocide, *Arquivos de Neuro-Psiquiatria*. 76(4), 277-282. <https://doi.org/10.1590/0004-282X20180022>
- Archer, J. (2006). Testosterone and human aggression: an evaluation of the challenge hypothesis. *Neuroscience and Biobehavioral Reviews*, 30(3), 319-345.  
<https://doi.org/10.1016/j.neubiorev.2004.12.007>
- Argawal, B., Mittal, N., Bansal, P., & Garg, S. (2015). Sentiment analysis using common-sense and context information. *Computational Intelligence and Neuroscience*, 1-9.  
<https://doi.org/10.1155/2015/715730>
- Argyris, C. (1952). *The impact of budgets on people*. The Controllershship Foundation.
- Argyris, C. (1953). Human problems with budgets. *Harvard Business Review*, 31(1), 97-110.
- Arias, G., Walter, L. (2018). Phrenology and its implications: Brief history about a forgotten issue. *Revista chilena de neuro-psiquiatria*, 56(1), 36-45. <https://dx.doi.org/10.4067/s0717-92272018000100036>
- Arnold, A. P., & Breedlove, S. M. (1985). Organizational and activational effects of sex steroids on brain and behavior: A reanalysis. *Hormones and Behavior*, 19(4), 469-498.  
[https://doi.org/10.1016/0018-506x\(85\)90042-x](https://doi.org/10.1016/0018-506x(85)90042-x)
- Badertscher, B. A., Katz, S. P., Rego, S. O., & Wilson, R. J. (2019). Conforming tax avoidance and capital market pressure. *The Accounting Review*, 94(6), 1-30. <https://doi.org/10.2308/accr-52359>
- Balakrishnan, K., Blouin, J. L., & Guay, W. R. (2019). Tax aggressiveness and corporate transparency. *The Accounting Review*, 94(1), 45-69. <https://doi.org/10.2308/accr-52130>

- Belkaoui, A. (1989). *Behavioral accounting: the research and practical issues*. Westport, Connecticut: Quorum Books.
- Ben-David, I., Graham, J. R., & Harvey, C. R. (2013). Managerial miscalibration. *The Quarterly Journal of Economics*, 128(4), 1547–1584. <https://www.jstor.org/stable/26372532>
- Bergstresser, D., & Philippon, T. (2006). CEO incentives and earnings management. *Journal of Financial Economics*, 80(3), 511-529. <https://doi.org/10.1016/j.jfineco.2004.10.011>
- Birnberg, J. G. (2011). A proposed framework for behavioral accounting research. *Behavioral Research in Accounting*, 23(1), 1-43. <https://doi.org/10.2308/bria.2011.23.1.1>
- Blascovich, J., Loomis, J., Beall, A. C., Swinth, K. R., Hoyt, C. L., & Bailenson, J. N. (2002). Immersive virtual environment technology as a methodological tool for social psychology. *Psychological Inquiry*, 13(2), 103–124. [https://doi.org/10.1207/S15327965PLI1302\\_01](https://doi.org/10.1207/S15327965PLI1302_01)
- Boyd, D., & Crawford, K. (2012). Critical questions for Big Data. *Information, Communication and Society*, 15(5), 662-679. <https://doi.org/10.1080/1369118X.2012.678878>
- Bratko, D., & Butkovic, A. (2007). Stability of genetic and environmental effects from adolescence to young adulthood: Results of Croatian longitudinal twin study of personality. *Twin Research and Human Genetics*, 10(1), 151–157. <https://doi.org/10.1375/twin.10.1.151>
- Brody, N. (1997). Dispositional paradigms: Comment on Eysenck (1997) and the biosocial science of individual differences. *Journal of Personality and Social Psychology*, 73(6), 1242–1245. <https://doi.org/10.1037/0022-3514.73.6.1242>
- Burgstahler, D., & Dichev, I. (1997). Earnings management to avoid earnings decreases and losses. *Journal of Accounting and Economics*, 24(1), 99-126. [https://doi.org/10.1016/S0165-4101\(97\)00017-7](https://doi.org/10.1016/S0165-4101(97)00017-7)
- Cambria, E., & White, B. (2014). Jumping NLP curves: A review of natural language processing research. *IEEE Computational Intelligence Magazine*, 9(2), 48-57. <https://doi.org/10.1109/MCI.2014.2307227>
- Carré, J. M., & McCormick, C. M. (2008). In your face: Facial metrics predict aggressive behavior in the laboratory and in varsity and professional hockey players. *Proceedings of the Royal Society B: Biological Sciences*, 275(1651), 2651–2656.
- Carré, J. M., Murphy, K. R., & Hariri, A. R. (2013). What lies beneath the face of aggression? *Social Cognitive and Affective Neuroscience*, 8(2), 224–229. <https://doi.org/10.1093/scan/nsr096>
- Carvalho, J. M. S., & Conde, A. (2024). Individual power in human motivation – Review and theoretical perspective. *Acta Psychologica*, 249, 104452. <https://doi.org/10.1016/j.actpsy.2024.104452>
- Carter, M. E., Lynch, L. J., & Zechman, S. L. C. (2009). Changes in bonus contracts in the post-Sarbanes–Oxley era. *Review of Accounting Studies*, 14(4), 480-506. <https://doi.org/10.1007/s11142-008-9082-7>
- Chan, K. H., & Wang, R. R. (2021). The macbeth factor: the dark side of achievement-driving analysts. *Abacus*, 57(2), 325-361. <https://doi.org/10.1111/abac.12187>

- Chava, S., & Purnanandam, A. (2010). CEOs versus CFOs: Incentives and corporate policies. *Journal of Financial Economics*, 97(2), 263-278. <https://doi.org/10.1016/j.jfineco.2010.03.018>
- Chen, S., Chen, X., Cheng, Q., & Shevlin, T. (2010). Are family firms more tax aggressive than non-family firms? *Journal of Financial Economics*, 95(1), 41-61. <https://doi.org/10.1016/j.jfineco.2009.02.003>
- Cheng, Q., & Warfield, T. D. (2005). Equity incentives and earnings management. *The Accounting Review*, 80(2), 441-476. <https://doi.org/10.2308/accr.2005.80.2.441>
- Choudhury, P., Wang, D., Carlson, N. A., & Khanna, T. (2019). Machine learning approaches to facial and text analysis: Discovering CEO oral communication styles. *Strategic Management Journal*, 40(11), 1705-1732. <https://doi.org/10.1002/smj.3067>
- Cohen, D. A., & Zarowin, P. (2010). Accrual-based and real earnings management activities around seasoned equity offerings. *Journal of Accounting and Economics*, 50(1), 2-19. <https://doi.org/10.1016/j.jacceco.2010.01.002>
- Colville, I. (1981). Reconstructing "behavioural accounting". *Accounting, Organizations and Society*, 6(2), 119-132. [https://doi.org/10.1016/0361-3682\(81\)90002-7](https://doi.org/10.1016/0361-3682(81)90002-7)
- Cooper, C. (2010). *Individual differences and personality* (3<sup>a</sup> ed.). Hodder Education.
- Costa, P. T., & McCrae, R. R. (1988). Personality in adulthood: A six-year longitudinal study of self-reports and spouse ratings on the NEO Personality Inventory. *Journal of Personality and Social Psychology*, 54(5), 853-863. <https://doi.org/10.1037/0022-3514.54.5.853>
- Costa, P. T., & McCrae, R. R. (1992). The five-factor model of personality and its relevance to personality disorders. *Journal of Personality Disorders*, 6(4), 343-359. <https://doi.org/10.1521/pedi.1992.6.4.343>
- Davis, J. G., & Garcia-Cestona, M. (2023). CEO age, financial reporting quality, and the role of clawback provisions. *Journal of Financial Reporting and Accounting*. <https://doi.org/10.1108/JFRA-11-2022-0356>
- Davis, A. K., Guenther, D. A., Krull, L. K., & Williams, B. M. (2016). Do socially responsible firms pay more taxes? *The Accounting Review*, 91(1), 47-68. <https://doi.org/10.2308/accr-51224>
- DeAngelo, H., DeAngelo, L. & Skinner, D. (1994). Accounting choice in troubled companies, *Journal of Accounting and Economics*, 17(1-2), 113-143. [https://doi.org/10.1016/0165-4101\(94\)90007-8](https://doi.org/10.1016/0165-4101(94)90007-8)
- Dechow, P. M., & Sloan, R. G. (1991). Executive incentives and the horizon problem: An empirical investigation. *Journal of Accounting and Economics*, 14(1), 51-89. [https://doi.org/10.1016/0167-7187\(91\)90058-S](https://doi.org/10.1016/0167-7187(91)90058-S)
- Dechow, P. M., Sloan, R. G., & Sweeney, A. P. (1995). Detecting earnings management. *The Accounting Review*, 70(2), 193-225. <https://www.jstor.org/stable/248303>
- Dechow, P. M., Sloan, R. G., & Sweeney, A. P. (1996). Causes and consequences of earnings manipulation: An analysis of firms subject to enforcement actions by the SEC. *Contemporary Accounting Research*, 13(1), 1-36. <https://doi.org/10.1111/j.1911-3846.1996.tb00489.x>
- DeGeorge, F., Patel, J., & Zeckhauser, R. (1999). Earnings management to exceed thresholds. *Journal of Business*, 72(1), 1-33. <https://doi.org/10.1086/209601>

- Durkheim, E. (2007). *As regras do método sociológico* (P. Neves, Trad., 3ª ed.). Martins Fontes. (Obra original publicada em 1895).
- Durkee, P. K., & Ayers, J. D. (2021). Is facial width-to-height ratio reliably associated with social inferences? *Evolution and Human Behavior*, 42(6), 583-592. <https://doi.org/10.1016/j.evolhumbehav.2021.06.003>
- Dyreng, S. D., Hanlon, M., & Maydew, E. L. (2008). Long-run corporate tax avoidance. *The Accounting Review*, 83(1), 61–82. <https://doi.org/10.2308/accr.2008.83.1.61>
- Dyreng, S. D., Hanlon, M., & Maydew, E. L. (2010). The effects of executives on corporate tax avoidance. *The Accounting Review*, 85(4), 1163–1189. <https://doi.org/10.2308/accr.2010.85.4.1163>
- Dyreng, S. D., Hanlon, M., & Maydew, E. L. (2019). When does tax avoidance result in tax uncertainty? *The Accounting Review*, 94(2), 179-203. <https://doi.org/10.2308/accr-52198>
- Fee, C. E., Hadlock, C. J., & Pierce, J. R. (2013). Managers with and without style: evidence using exogenous variation, *The Review of Financial Studies*, 26(3), pp. 567–601, <https://doi.org/10.1093/rfs/hhs131>
- Ferris, S.P., Jagannathan, M. and Pritchard, A.C. (2003) Too Busy to Mind the Business? Monitoring by Directors with Multiple Board Appointments. *The Journal of Finance*, 58, 1087-1111. <https://doi.org/10.1111/1540-6261.00559>
- 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)
- Figueredo, A. J., Vásquez, G., Brumbach, B. H., Schneider, S. M. R., Sefcek, J. A., Tal, I. R., Hill, D., Wenner, C. J., & Jacobs, W. J. (2006). Consilience and Life History Theory: From genes to brain to reproductive strategy. *Developmental Review*, 26(2), 243–275. <https://doi.org/10.1016/j.dr.2006.02.002>
- Finkelstein, S., Hambrick, D. C., & Cannella, A. A., (2009). *Strategic leadership: Theory and research on executives, top management teams, and boards*. Oxford University Press. <https://doi.org/10.1093/acprof:oso/9780195162073.001.0001>
- Fitza, M. A. (2017). How much do CEOs really matter? Reaffirming that the CEO effect is mostly due to chance. *Strategic Management Journal*, 38(3), 802-811. <https://doi.org/10.1002/smj.2597>
- Florackis, C., & Sainani, S. (2021). Can CFOs resist undue pressure from CEOs to manage earnings? *Journal of Corporate Finance*, 67, 101859. <https://doi.org/10.1016/j.jcorpfin.2020.101859>
- Frank, M. Z. & Goyal, V. K. (2007) Corporate Leverage: How Much Do Managers Really Matter? SSRN 971082. <http://dx.doi.org/10.2139/ssrn.971082>
- Frank, M. M., Lynch, L. J., & Rego, S. O. (2009). Tax reporting aggressiveness and its relation to aggressive financial reporting. *The Accounting Review*, 84(2), 467–496. <https://doi.org/10.2308/accr.2009.84.2.467>
- Galdi, F. C., & Gonçalves, A. M. (2018). Pessimismo e incerteza das notícias e o comportamento dos investidores no Brasil. *Revista de Administração de Empresas*, 58(2), 130-148. <https://doi.org/10.1590/S0034-759020180203>

- Ge, W., Matsumoto, D., & Zhang, J. L. (2011). Do CFOs have style? An empirical investigation of the effect of individual CFOs on accounting practices. *Contemporary Accounting Research*, 28(4), 1141-1179. <https://doi.org/10.1111/j.1911-3846.2011.01097.x>
- Geniole, S. N., Molnar, D. S., Carré, J. M., & McCormick, C. M. (2014). The facial width-to-height ratio shares stronger links with judgments of aggression than with judgments of trustworthiness. *Journal of Experimental Psychology: Human Perception and Performance*, 40(4), 1526–1541. <https://doi.org/10.1037/a0036732>
- Goergen, M., & Renneboog, L. (2011). Managerial compensation. *Journal of Corporate Finance*, 17(4), 1068-1077. <https://doi.org/10.1016/j.jcorpfin.2011.06.002>
- Graham, J. R., Harvey, C. R., & Puri, M. (2013). Managerial attitudes and corporate actions. *Journal of Financial Economics*, 109(1), 103-121. <https://doi.org/10.1016/j.jfineco.2013.01.010>
- Graham, J. R., Hanlon, M., Shevlin, T., & Shroff, N. (2017). Tax rates and corporate decision-making. *The Review of Financial Studies*, 30(9), 3128–3175. <https://doi.org/10.1093/rfs/hhx037>
- Graham, J. R., Harvey, C. R., & Rajgopal, S. (2005). The economic implications of corporate financial reporting. *Journal of Accounting and Economics*, 40(1-3), 3-73. <https://doi.org/10.1016/j.jacceco.2005.01.002>
- Graham, J. R., & Tucker, A. L. (2006). Tax shelters and corporate debt policy. *Journal of Financial Economics*, 81(3), 563-594. <https://doi.org/10.1016/j.jfineco.2005.09.002>
- Greenfield, A., Norman, C., & Wier, B. (2008). The effect of ethical orientation and professional commitment on earnings management behavior. *Journal of Business Ethics* 83(3), 419–434. <https://doi.org/10.1007/s10551-007-9629-4>
- Guenther, D. A., Wilson, R. J., & Wu, K. (2019). Tax uncertainty and incremental tax avoidance. *The Accounting Review*, 94(2), 229-247. <https://doi.org/10.2308/accr-52194>
- Hair, J. F., & Fávero, L. P. L. (2019). Multilevel modeling for longitudinal data: Concepts and applications. *RAUSP Management Journal*. <https://doi.org/10.1108/RAUSP-04-2019-0059>
- Hambrick, D. C. (2007). Upper echelons theory: An update. *Academy of Management Review*, 32(2), 334-343. <https://doi.org/10.5465/amr.2007.24345254>
- Hambrick, D. C., & Mason, P. A. (1984). Upper echelons: The organization as a reflection of its top managers. *Academy of Management Review*, 9(2), 193-206. <https://doi.org/10.5465/amr.1984.4277628>
- Hanlon, M., & Heitzman, S. (2010). A review of tax research. *Journal of Accounting and Economics*, 50(2), 127-178. <https://doi.org/10.1016/j.jacceco.2010.09.002>
- Haselhuhn, M. P., & Wong, E. M. (2012). Bad to the bone: facial structure predicts unethical behaviour. *Proceedings of the Royal Society B: Biological Sciences*, 279(1728), 571-576. <https://doi.org/10.1098/rspb.2011.1193>
- Hazarika, S., Karpoff, J. M., & Nahata, R. (2012). Internal corporate governance, CEO turnover, and earnings management. *Journal of Financial Economics*, 104(1), 44-69. <https://doi.org/10.1016/j.jfineco.2011.10.011>

- He, X., Yin, H., Zeng, Y., Zhang, H., & Zhao, H. (2019). Facial structure and achievement drive: Evidence from financial analysts. *Journal of Accounting Research*, 57(4), 1013–1057. <https://doi.org/10.1111/1475-679X.12259>
- Healy, P. M. (1985). The effect of bonus schemes on accounting decisions. *Journal of Accounting and Economics*, 7(1-3), 85-107. [https://doi.org/10.1016/0165-4101\(85\)90029-1](https://doi.org/10.1016/0165-4101(85)90029-1)
- Healy, P. M., & Wahlen, J. M. (1999). A review of the earnings management literature and its implications for standard setting. *Accounting Horizons*, 13(4), 365-383. <https://doi.org/10.2308/acch.1999.13.4.365>
- Herbert, J. (2018). Testosterone, cortisol and financial risk-taking. *Frontiers in Behavioral Neuroscience*, 12, Article 101. <https://doi.org/10.3389/fnbeh.2018.00101>
- Hofstede, T. R. (1976). Behavioral accounting research: pathologies, paradigms and prescriptions. *Accounting, Organizations and Society*, 1(1), 43-58. [https://doi.org/10.1016/0361-3682\(76\)90006-4](https://doi.org/10.1016/0361-3682(76)90006-4)
- Holthausen, R. W., Larcker, D. F., & Sloan, R. G. (1995). Annual bonus schemes and the manipulation of earnings. *Journal of Accounting and Economics*, 19(1), 29-74. [https://doi.org/10.1016/0165-4101\(94\)00376-G](https://doi.org/10.1016/0165-4101(94)00376-G)
- Hoque, Z., & Mai, K. (2018). Human relations theory. In Z. Hoque (Ed.), *Methodological issues in accounting research: Theories and methods* (2nd ed.). Spiramus Press.
- Hsieh, T.-S., Bedard, J. C., & Johnstone, K. M. (2014). CEO overconfidence and earnings management during shifting regulatory regimes. *Journal of Business Finance & Accounting*, 41(9-10), 1243-1268. <https://doi.org/10.1111/jbfa.12089>
- Jaggi, B., & Lee, P. (2002). Earnings Management Response to Debt Covenant Violations and Debt Restructuring. *Journal of Accounting, Auditing & Finance*, 17(4), 295-324. <https://doi.org/10.1177/0148558X0201700402>
- James, H. L. (2020). CEO age and tax planning. *Review of Financial Economics*, 38(2), 275-299. <https://doi.org/10.1002/rfe.1072>
- Jbir, S., Neifar, S., & Fourati, Y. M. (2021). CEO compensation, CEO attributes and tax aggressiveness: Evidence from French firms listed on the CAC 40. *Journal of Financial Crime*, 28(4), 1141-1160. <https://doi.org/10.1108/JFC-10-2020-0202>
- Jensen, M. C. (1993). The modern industrial revolution, exit, and the failure of internal control systems. *The Journal of Finance*, 48(3), 831-880. <https://doi.org/10.1111/j.1540-6261.1993.tb04022.x>
- Jia, Y., Van Lent, L., & Zeng, Y. (2014). Masculinity, testosterone, and financial misreporting. *Journal of Accounting Research*, 52(5), 1195-1246. <https://doi.org/10.1111/1475-679X.12065>
- Jones, J. (1991). Earnings management during import relief investigations. *Journal of Accounting Research*, 29(2), 193-228. <https://doi.org/10.2307/2491047>
- Kachur, A., Osin, E., Davydov, D., Shutilov, K., & Novokshonov, A. (2020). Assessing the Big Five personality traits using real-life static facial images. *Scientific Reports*, 10, 8487. <https://doi.org/10.1038/s41598-020-65358-6>
- Kamiya, S., Kim, Y. H., & Park, S. (2019). The face of risk: CEO facial masculinity and firm risk. *European Financial Management*, 25(2), 239-270. <https://doi.org/10.1111/eufm.12175>

- Kapoor, S., & Prosad, J. M. (2017). Behavioural finance: a review. *Procedia Computer Science*, 122, 50-54. <https://doi.org/10.1016/j.procs.2017.11.340>
- Kelton, A. S., & Pennington, R. R. (2020). If you tweet, they will follow: CEO tweets, social capital, and investor say-on-pay judgments. *Journal of Information Systems*, 34(1), 105-122. <https://doi.org/10.2308/isys-52449>
- Kitchin, R. (2013). Big data and human geography: opportunities, challenges and risks. *Dialogues in Human Geography*, 3(3), 262-267. <https://doi.org/10.1177/2043820613513388>
- Kovermann, J., & Wendt, M. (2019). Tax avoidance in family firms: Evidence from large private firms. *Journal of Contemporary Accounting & Economics*, 15(2), 145-157. <https://doi.org/10.1016/j.jcae.2019.04.003>
- Kuhnen, C., & Chiao, J. (2009). Genetic determinants of financial risk taking. *PLoS ONE*, 4(2), e4362. <https://doi.org/10.1371/journal.pone.0004362>
- Kutluk, F. A., & Ersoy, A. (2010). Literature review of behavioral research in accounting between 1999-2008. *Journal of Yasar University*, 5(19), 3171-3198.
- Labelle, R., Makni Gargouri, R., & Francoeur, C. (2010). Ethics, diversity management, and financial reporting quality. *Journal of Business Ethics* 93(2), 335–353. <https://doi.org/10.1007/s10551-009-0225-7>
- Lanis, R., & Richardson, G. (2012). Corporate social responsibility and tax aggressiveness: A test of legitimacy theory. *Journal of Accounting and Public Policy*, 31(1), 86-108. <https://doi.org/10.1016/j.jaccpubpol.2011.10.006>
- Lawrence, B. S. (1997). The Black Box of Organizational Demography. *Organization Science*, 8(1), 1-22. <https://doi.org/10.1287/orsc.8.1.1>
- Lennox, C., Lisowsky, P., & Pittman, J. (2013). Tax aggressiveness and accounting fraud. *Journal of Accounting Research*, 51(4), 739-778. <https://doi.org/10.1111/joar.12002>
- Lefevre, C. E., Lewis, G. J., Perrett, D. I., & Penke, L. (2013). Telling facial metrics: Facial width is associated with testosterone levels in men. *Evolution and Human Behavior*, 34(4), 273–279. <https://doi.org/10.1016/j.evolhumbehav.2013.03.005>
- Leonelli, S. (2017). Global data quality assessment and the situated nature of “best” research practices in biology. *Data Science Journal*, 16(32), 1-11. <https://doi.org/10.5334/dsj-2017-032>
- Lev, B. (1989). On the usefulness of earnings and earnings research: Lessons and directions from two decades of empirical research. *Journal of Accounting Research*, 27, 153-192. <https://doi.org/10.2307/2491070>
- Levine, P. (2010). Anthropology, colonialism, and eugenics. In A. Bashford & P. Levine (Eds.), *The Oxford handbook of the history of eugenics* (pp. 43-61). Oxford University Press. <https://doi.org/10.1093/oxfordhb/9780195373141.013.0003>
- Lewis, G. J., Lefevre, C. E., & Bates, T. C. (2012). Facial width-to-height ratio predicts achievement drive in US presidents. *Personality and Individual Differences*, 52(7), 855-857. <https://doi.org/10.1016/j.paid.2011.12.030>
- Li, X., Low, A., & Makhija, A. K. (2017). Career concerns and the busy life of the young CEO. *Journal of Corporate Finance*, 47, 88-109. <https://doi.org/10.1016/j.jcorpfin.2017.09.006>

- Liao, Z., Tilley, S., Mouraviev, A., Khairullah, A., & Paus, T. (2021). Pubertal testosterone and brain response to faces in young adulthood: an interplay between organizational and activation effects in young men. *The Journal of Neuroscience*, 41(13), pp. 2990-2999. <https://doi.org/10.1523/JNEUROSCI.0190-20.2021>
- Libby, R., Bloomfield, R., & Nelson, M. W. (2002). Experimental research in financial accounting. *Accounting, Organizations and Society*, 27(8), 775-810. [https://doi.org/10.1016/S0361-3682\(01\)00011-3](https://doi.org/10.1016/S0361-3682(01)00011-3)
- Lieberson, S., & O'Connor, J. F. (1972). Leadership and organizational performance: A study of large corporations. *American Sociological Review*, 37(2), 117-130. <https://doi.org/10.2307/2094020>
- Lin, F., Lin, S.-W., & Fang, W.-C. (2020). How CEO narcissism affects earnings management behaviors. *The North American Journal of Economics and Finance*, 51, 101080. <https://doi.org/10.1016/j.najef.2019.101080>
- Linstead, S. (1997). The social anthropology of management. *British Journal of Management*, 8(1), 85-98. <https://doi.org/10.1111/1467-8551.00042>
- Major, M. J. (2008). Reflexão sobre a investigação em contabilidade de gestão. *Revista Portuguesa e Brasileira de Gestão*, 7(4), 43-50. Recuperado d: <https://periodicos.fgv.br/rbpg/article/view/78884>
- Malmendier, U., & Tate, G. (2005). CEO overconfidence and corporate investments. *The Journal of Finance*, 60(6), 2661–2701. <https://doi.org/10.1111/j.1540-6261.2005.00813.x>
- Martinez, A. L. (2008). Detectando earnings management no Brasil: estimando os accruals discricionários. *Revista Contabilidade & Finanças*, 19(46), 7-17. <https://doi.org/10.1590/S1519-70772008000100002>
- Mazur, A., & Booth, A. (1998). Testosterone and dominance in men. *Behavioral and Brain Sciences*, 21(3), 353-363. <https://doi.org/10.1017/S0140525X98001228>
- Meyer, M., & Rigsby, J. T. (2001). A descriptive analysis of the content and contributors of behavioral research in accounting 1989-1998. *Behavioral Research in Accounting*, 13(1), 253-278. <https://doi.org/10.2308/bria.2001.13.1.253>
- Mills, L., Erickson, M. M., & Maydew, E. L. (1998). Investments in Tax Planning. *The Journal of the American Taxation Association*, 20, 1-20. <https://doi.org/10.2308/jata.2001.23.1.1>
- Minnick, K., & Noga, T. (2010). Do corporate governance characteristics influence tax management? *Journal of Corporate Finance*, 16(5), 703-718. <https://doi.org/10.1016/j.jcorpfin.2010.08.005>
- Mo, T. T., Ha, H. T. T., & Diep, N. T. T. (2023). The impact of firm leverage on investment decisions: The new approach of hierarchical method. *Banking & Finance*. <https://doi.org/10.1080/23311975.2023.2209380>
- Monsalves, M. J., Bangdiwala, A. S., Thabane, A., & Bangdiwala, S. I. (2020). LEVEL (Logical Explanations & Visualizations of Estimates in Linear mixed models): Recommendations for reporting multilevel data and analyses. *BMC Medical Research Methodology*, 20(3). <https://doi.org/10.1186/s12874-019-0876-8>
- Moore, D. (2015). *The developing genome: An introduction to behavioral epigenetics*. Oxford University Press.



- Motoki, K., & Sugiura, M. (2017). Consumer behavior, hormones, and neuroscience: Integrated understanding of fundamental motives why we buy. *Psychologia*, 60(1), 28-43. <https://doi.org/10.2117/psysoc.2017.28>
- Murphy, P., Wynes, M., Hahn, T., & Devine, P. (2020). Why are people honest? Internal and external motivations to report honestly. *Contemporary Accounting Research*, 37(2), 945-981. <https://doi.org/10.1111/1911-3846.12543>
- Murphy, K. J., & Zimmerman, J. L. (1993). Financial performance surrounding CEO turnover. *Journal of Accounting and Economics*, 16 (1-3): 273-315. [https://doi.org/10.1016/0165-4101\(93\)90014-7](https://doi.org/10.1016/0165-4101(93)90014-7)
- Naqvi, S., Sley, Y., Hoskens, H., et al. (2021). Shared heritability of human face and brain shape. *Nature Genetics*, 53, 830-839. <https://doi.org/10.1038/s41588-021-00827-w>
- Paul, D. B., & Moore, J. (2012). The Darwinian context: Evolution and inheritance. In A. Bashford & P. Levine (Eds.), *The Oxford Handbook of the History of Eugenics* (pp. 27-42). Oxford University Press. <https://doi.org/10.1093/oxfordhb/9780195373141.013.0002>
- Peci, A. (2003). Estrutura e ação nas organizações: algumas perspectivas sociológicas. *Revista de Administração de Empresas*, 43(1), 1-12. <https://doi.org/10.1590/S0034-75902003000100004>
- Peni, E., & Vähämaa, S. (2010). Female executives and earnings management. *Managerial Finance*, 36(7), 629-645. <https://doi.org/10.1108/03074351011050343>
- Pfeffer, J. (1983). Organizational Demography, in L. L. Cummings and B. M. Staw (Eds.), *Research in Organizational Behavior*, 5, pp. 299-357, JAI Press
- Plomin, R., Chipuer, H. M., & Loehlin, J. C. (1990). Behavioral genetics and personality. In L. A. Pervin (Ed.), *Handbook of personality: theory and research* (pp. 225-243). The Guilford Press.
- Pound, N., Penton-Voak, I. S., & SurrIDGE, A. K. (2009). Testosterone responses to competition in men are related to facial masculinity. *Proceedings of the Royal Society B: Biological Sciences*, 276(1654), 153-159. <https://doi.org/10.1098/rspb.2008.0990>
- Putra, A. A., & Setiawan, D. (2024). Do CEO characteristics affect earnings management? *Corporate Governance*, 24(5), 1137-1155. <https://doi.org/10.1108/CG-02-2023-0078>
- Resick, C. J., Whitman, D. S., Weingarden, S. M., & Hiller, N. J. (2009). The bright-side and the dark-side of CEO personality: Examining core self-evaluations, narcissism, transformational leadership, and strategic influence. *Journal of Applied Psychology*, 94(6), 1365-1381. <https://doi.org/10.1037/a0016238>
- Roberts, M. R., & Whited, T.M. (2013). Endogeneity in empirical corporate finance. *Handbook of the Economics of Finance*, 2, 493-572.
- Rönkkö, M., Maheshwaree, P., & Schmidt, J. (2023). The CEO effect and performance variation over time. *The Leadership Quarterly*, 34(5), 101733. <https://doi.org/10.1016/j.leaqua.2023.101733>
- Rose, A. M., Rose, J. M., Rotaru, K., Sanderson, K., & Thibodeau, J. C. (2022). Effects of uncertainty visualization on attention, arousal, and judgement. *Behavioral Research in Accounting*, 34(1), 113-139. <https://doi.org/10.2308/BRIA-2021-011>

- Rosenbaum, P. R., & Rubin, D. B. (1983). The central role of the propensity score in observational studies for causal effects. *Biometrika*, 70(1), 41-55. <https://doi.org/10.2307/2335942>
- Roychowdhury, S. (2006). Earnings management through real activities manipulation. *Journal of Accounting and Economics*, 42(3), 335-370. <https://doi.org/10.1016/j.jacceco.2006.01.002>
- Ryan, R., & Deci, E. L. (2000). Self-determination theory and the facilitation of intrinsic motivation, social development, and well-being. *The American Psychologist*, 55(1), 68-78. <https://doi.org/10.1037//0003-066x.55.1.68>
- Sætra, H. S. (2018). Science as a vocation in the era of Big Data: the philosophy of science behind Big Data and humanity's continued part in science. *Integrative Psychological and Behavioral Science*, 52(4), 508-522. <https://doi.org/10.1007/s12124-018-9447-5>
- Sapienza, P., Zingales, L., & Maestripieri, D. (2009). Gender differences in financial risk aversion and career choices are affected by testosterone. *Proceedings of the National Academy of Sciences*, 106(36), 15268-15273. <https://doi.org/10.1073/pnas.0907352106>
- Schultz, D. P., & Schultz, S. E. (2016). *Theories of personality*. Cengage Learning.
- Schwab, C. M., Stomberg, B., & Williams, B. M. (2022). Effective Tax Planning. *The Accounting Review*, 97(1), 413–437. <https://doi.org/10.2308/TAR-2019-0020>
- Shipman, J. E., Swanquist, Q. T., & Whited, R. L. (2017). Propensity score matching in accounting research. *The Accounting Review*, 92(1), 213-244. <https://doi.org/10.2308/accr-51449>
- Siegel, G., & Ramanauskas-Marconi, H. (1989). *Behavioral accounting*. Ohio: South-Western Publishing Co.
- Sikka, P. (2010). Smoke and mirrors: Corporate social responsibility and tax avoidance. *Accounting Forum*, 34(3-4), 153-168. <https://doi.org/10.1016/j.accfor.2010.05.002>
- Sisk, C. L., & Foster, D. L. (2004). The neural basis of puberty and adolescence. *Nature Neuroscience*, 7(10), 1040-1047. <https://doi.org/10.1038/nn1326>
- Sisk, C., Lonstein, J. S., & Gore, A. C. (2013). Critical periods during development: hormonal influences on neurobehavioral transitions across the life span. In: D. W. Pfaff (Ed.), *Neuroscience in the 21st Century*. Springer. [https://doi.org/10.1007/978-1-4614-1997-6\\_61](https://doi.org/10.1007/978-1-4614-1997-6_61)
- Steinberg L. (2008). A Social Neuroscience Perspective on Adolescent Risk-Taking. *Developmental review : DR*, 28(1), 78–106. <https://doi.org/10.1016/j.dr.2007.08.002>
- Stelmack, R. M. (1997). Toward a paradigm in personality: Comment on Eysenck's (1997) view. *Journal of Personality and Social Psychology*, 73(6), 1238–1241. <https://doi.org/10.1037/0022-3514.73.6.1238>
- Sternam R., & Zibrek, K. (2021). Psychology in virtual reality: Toward a validated measure of social presence. *Frontiers in Psychology*, 12, 705448. <https://doi.org/10.3389/fpsyg.2021.705448>
- Stuart, E. A. (2010). Matching methods for causal inference: A review and a look forward. *Statistical Science*, 25(1), 1-21. <https://doi.org/10.1214/09-STS313>

- Stubben, S. R. (2010). Discretionary revenues as a measure of earnings management. *The Accounting Review*, 85(2), 695-717. <https://doi.org/10.2308/accr.2010.85.2.695>
- Tetlock, P. C., Saar-Tsechansky, M., & Macskassy, S. (2008). More than words: Quantifying language to measure firms' fundamentals. *The Journal of Finance*, 63(3), 1437-1467. <https://doi.org/10.1111/j.1540-6261.2008.01362.x>
- Verdonck, A., Gaethofs, M., Carels, C., & de Zegher, F. (1999). Effect of low-dose testosterone treatment on craniofacial growth in boys with delayed puberty. *European journal of orthodontics*, 21(2), 137-143. <https://doi.org/10.1093/ejo/21.2.137>
- Warren, J. D., Moffitt, K. C., & Byrnes, P. (2015). How Big Data will change accounting. *Accounting Horizons*, 29(2), 397-407. <https://doi.org/10.2308/acch-51069>
- Wilson, R. J. (2009). An examination of corporate tax shelter participants. *The Accounting Review*, 84(3), 969-999. <https://doi.org/10.2308/accr.2009.84.3.969>
- Ye, K., Zhang, R. & Rezaee, Z. (2010). Does top executive gender diversity affect earnings quality? A large sample analysis of Chinese listed firms. *Advances in Accounting*, 26(1), 47-54. <https://doi.org/10.1016/j.adiac.2010.02.008>
- Zak, P. J. (2018). The neuroscience of high-trust organizations. *Consulting Psychology Journal: Practice and Research*, 70(1), 45-58. <https://doi.org/10.1037/cpb0000076>
- Zang, A. Y. (2012). Evidence on the Trade-Off between Real Activities Manipulation and Accrual-Based Earnings Management. *The Accounting Review*, 87(2), 675-703. <https://doi.org/10.2308/accr-10196>
- Zhang, J., Yang, X., & Appelbaum, D. (2015). Toward effective Big Data analysis in continuous auditing. *Accounting Horizons*, 29(2), 469-476. <https://doi.org/10.2308/acch-51070>
- Zola-Morgan, S. (1995). Localization of brain function: The legacy of Franz Joseph Gall (1758-1828). *Annual Review of Neuroscience*, 18, 359-383. <https://doi.org/10.1146/annurev.ne.18.030195.002043>

## APÊNDICE A – PROCEDIMENTOS ADOTADOS PARA O CÁLCULO DA FWHR

Este apêndice descreve os procedimentos utilizados para o cálculo da *facial width-to-height ratio* (fWHR) dos CEOs presentes em nossa amostra. Inicialmente, após a listagem completa dos nomes dos CEOs e das suas respectivas empresas, com base nos dados da base *Execucomp* para o período em análise, procedemos à busca das imagens faciais adequadas. Essas imagens foram coletadas em fontes confiáveis, como os sites oficiais das empresas, a plataforma Bloomberg e outros sites empresariais e de negócios reconhecidos. A seleção criteriosa dessas imagens teve o intuito de garantir que todas fossem consistentes e adequadas para o processamento subsequente.


Para mitigar possíveis distorções ou variações não intencionais, utilizamos a ferramenta de busca Google Imagens para coletar múltiplas fotos de cada CEO. As fotos escolhidas respeitavam critérios rigorosos: foram selecionados apenas retratos em que as duas orelhas estavam visíveis e o rosto dos CEOs não apresentava inclinações significativas para cima ou para baixo. Após esse processo, conseguimos reunir um total de 1.920 fotos de diretores distintos.

A etapa subsequente envolveu o desenvolvimento de um algoritmo em Python, utilizando a biblioteca *dlib*. Esse algoritmo foi projetado para alinhar as imagens, padronizar a resolução e as cores, além de reconhecer automaticamente as faces e seus respectivos *landmarks* (pontos de referência faciais). Os *landmarks* são identificados por um detector pré-treinado dentro da biblioteca *dlib*, chamado “*shape\_predictor\_68\_face\_landmarks.dat*”.

Após o reconhecimento facial, o algoritmo procede ao cálculo da fWHR, identificando as medidas de largura e altura do rosto de cada CEO, conforme detalhado a seguir.

A **Figura A1** apresenta os principais pontos de referência utilizados no processo de reconhecimento facial pelo *dlib*. Esses *landmarks* são pontos-chave da face, que possibilitam a correta identificação das proporções faciais. Posteriormente, na **Figura A2**, temos um exemplo de uma imagem de CEO, após passar pelo alinhamento e processamento automatizado.

Para o cálculo da fWHR, consideramos os seguintes parâmetros: a largura foi definida pela distância entre os *landmarks* 1 e 15, que correspondem aos dois pontos mais laterais da face (ossos zigomáticos). Já a altura foi calculada como a distância do ponto médio entre os *landmarks* 21 e 22 até o *landmark* 27 (que corresponde ao osso náseo), e do *landmark* 27 até o *landmark* 51 (correspondente ao osso próstio).

**Figura A1**

*Pontos de referência gerados pela biblioteca dlib*

**Figura A2**

*Exemplo da face de um CEO após imagem alinhada, processada e calculada a fWHR.*



Exemplo de imagem após ser alinhada, processada e ter os *landmarks* reconhecidos com *Dlib*. Fonte da imagem original: [https://www.dfinsolutions.com/sites/default/files/styles/text\\_image\\_image\\_2x/public/images/2019-06/dan-leib.jpg?itok=gasN1d9f](https://www.dfinsolutions.com/sites/default/files/styles/text_image_image_2x/public/images/2019-06/dan-leib.jpg?itok=gasN1d9f)

Essas medidas foram então usadas para calcular a fWHR, uma métrica amplamente utilizada na literatura para correlacionar características faciais com traços comportamentais, como dominância e assunção de riscos (Carré & McCormick, 2008). O código Python utilizado para o alinhamento, processamento e cálculo da fWHR pode ser acessado em <https://github.com/robertmuzy/fwhr>.

## APÊNDICE B – CONSTRUÇÃO E DEFINIÇÃO DAS VARIÁVEIS

Variável	Descrição e cálculo	Fonte dos dados
<i>Variáveis dependentes</i>		
<b>BTD Total</b>	Book-tax difference = $((\pi - mii) - ((\text{txfed} + \text{txfo}) / \text{corporate\_tax\_rate})) / \text{at}$ Em caso de dados faltantes, $((\pi - mii) - ((\text{txt} + \text{txdi}) / \text{corporate\_tax\_rate})) / \text{at}$ $\text{corporate\_tax\_rate} = 0,35$ (1998 a 2017) e $0,21$ (2018 a 2020)	Compustat
<b>BTD Perm</b>	BTD Permanente = BTD Total - BTD temporária BTD temporária = $(\text{txdi} / \text{corporate\_tax\_rate}) / \text{at}$	
<b>BTD Disc</b>	BTD Discricionária = Resíduos da regressão estimada com BTD Total como variável dependente, seguindo Frank et al. (2009)	
<b>ETR GAAP</b>	Effective Tax Rate = $\text{txt} / \pi$ , se $\text{txt} > 0$ e $\pi > 0$ (winsorizada entre 0 e 1)	
<b>CASH ETR</b>	Cash Effective tax rate = média de 3 ou 5 anos por código SIC e ano de $\text{txpd} / \pi$ , se $\text{txpd} > 0$ e $\pi > 0$ (winsorizada entre 0 e 1)	
<b>DACC</b>	Valor absoluto dos resíduos do modelo de Jones modificado por Dechow et al. (1995). Estimado por ano e código SIC de dois dígitos	
<b>ABN_CFO</b>	Fluxo de caixa operacional anormal = resíduos da regressão do modelo de Roychowdhury (2006). Estimado por ano e código SIC de dois dígitos Variável dependente = $\text{oancf} / \text{l.at}$	
<b>ABN_PROD</b>	Custo de produção anormal = resíduos da regressão do modelo de Roychowdhury (2006). Estimado por ano e código SIC de dois dígitos Variável dependente = $\text{cogs} + \text{d.invt}$	
<b>ABN_DISEXP</b>	Níveis anormais de despesas discricionárias estimados por ano e código SIC (dois dígitos), considerando resíduos do modelo de Roychowdhury (2006) Variável dependente = $\text{xad} + \text{xrd} + \text{xsga}$	
<b>REM</b>	$\text{REM} = -(\text{ABN\_CFO}) + (\text{ABN\_PROD}) - (\text{ABN\_DISEXP})$	
<i>Variáveis de interesse</i>		
<b>fCEO</b>	fwHR do CEO	Processo descrito no Apêndice A
<b>fCFO</b>	fwHR do CFO	
<i>Controle - Nível do diretor</i>		
<b>ΔCEO</b>	Diferença entre a fwHR do CEO corrente e a fwHR do CEO anterior. Esse valor é constante enquanto se mantém o CEO.	
<b>AGE</b>	Idade do diretor em anos	Execucomp
<b>TEN</b>	Mandato do CEO contado em anos, com casa decimais = diferença entre $\text{datadate}$ (Compustat) e $\text{BECAMECEO}$ (Execucomp).	Compustat/Execucomp
<b>INTL</b>	Interlock do CEO = variável indicadora que identifica se o CEO atua em conselho externo.	Execucomp
<b>GEN</b>	Gender (Sexo) = variável GENDER da Execucomp: 1 se masculino, 0 se feminino	Execucomp
<b>SAL</b>	Valor anormal do Salário mais bônus e outras compensações do CEO em comparação com a média por ano e setor, ajustado pelos ativos totais. A variável utilizada para o cálculo foi a TDC1 que soma todos os componentes da remuneração dos executivos.	Execucomp
<i>Controle - Nível da empresa</i>		
<b>BRD</b>	Tamanho do Conselho Administrativo	Execucomp
<b>SIZE</b>	Tamanho da empresa = $\ln(\text{at})$	Compustat
<b>TAN</b>	Tangibilidade = $\text{ppget} / \text{at}$	
<b>LIQ</b>	Liquidez = $\text{act} / \text{lct}$	

<b>GRW</b>	Sales growth (crescimento das vendas) = $(\text{sale} - \text{l.sale}) / \text{l.sale}$
<b>CAPx</b>	Capital expenditures (investimentos em bens de capital) = $\text{capx} / \text{at}$ , zero caso missing(capx)
<b>MTB</b>	Market-to-Book Ratio (razão valor de mercado / valor contábil) = $\text{mkvalt} / \text{ceq}$
<b>LEV</b>	Leverage (alavancagem financeira) = $(\text{dltt} + \text{dlc}) / \text{at}$
<b>NOL</b>	Prejuízo Fiscal a Compensar: variável binária = 0, caso missing(tlcf) e =1, caso contrário
<b><math>\Delta</math> NOL</b>	Variação do net operating loss carryforward = $(\text{tlcf} - \text{l.tlcf}) / \text{l.tlcf}$
<b>MULT</b>	Se multinacional: variável binária = 0, caso missing(pifo) e =1, caso contrário
<b>ROA</b>	Retorno sobre Ativos = $\text{ni} / \text{at}$
<b>EBTD</b>	EBITDA (lucro antes de juros, impostos, depreciação e amortização) = $\text{ebitda} / \text{at}$
<b>LOSS</b>	Net losses (prejuízo líquido) = variável que indica 1 se NI (net income) < 0

Compustat