

**FUNDAÇÃO ESCOLA DE COMÉRCIO ÁLVARES PENTEADO –  
FECAP  
CENTRO UNIVERSITÁRIO ÁLVARES PENTEADO  
MESTRADO EM CIÊNCIAS CONTÁBEIS**

**JAILSON EVANGELISTA**

**ESTUDO SOBRE A TEORIA DA DOMINÂNCIA  
TECNOLÓGICA NO USO DA INTELIGÊNCIA ARTIFICIAL  
APLICADA À GESTÃO TRIBUTÁRIA NO BRASIL**

**São Paulo**

**2020**

**JAILSON EVANGELISTA**

**ESTUDO SOBRE A TEORIA DA DOMINÂNCIA TECNOLÓGICA NO  
USO DA INTELIGÊNCIA ARTIFICIAL APLICADA À GESTÃO  
TRIBUTÁRIA NO BRASIL**

Dissertação apresentada à Fundação Escola de  
Comércio Álvares Penteado - FECAP, como  
requisito para a obtenção do título de Mestre em  
Ciências Contábeis.

**Orientador: Prof. Dr. Tiago Nascimento Borges  
Slavov**

**São Paulo**

**2020**

FUNDAÇÃO ESCOLA DE COMÉRCIO ÁLVARES PENTEADO - FECAP  
CENTRO UNIVERSITÁRIO ÁLVARES PENTEADO

Prof. Dr. Edison Simoni da Silva  
Reitor

Prof. Dr. Ronaldo Fróes de Carvalho  
Pró-reitor de Graduação

Prof. Dr. Alexandre Garcia  
Pró-reitor de Pós-Graduação

**FICHA CATALOGRÁFICA**

E92e

Evangelista, Jailson

Estudo sobre a teoria da dominância tecnológica no uso da inteligência artificial aplicada à gestão tributária no Brasil / Jailson Evangelista. - - São Paulo, 2020.

99 f.

Orientador: Prof. Dr. Tiago Nascimento Borges Slavov

Dissertação (mestrado) – Fundação de Escola de Comércio Álvares Penteado – FECAP – Centro Universitário Álvares Penteado – Programa de Mestrado em Ciências Contábeis.

1. Contabilidade - Processamento de dados. 2. Sistemas de recuperação da informação – Contabilidade. 3. Inteligência artificial. 4. Planejamento tributário.

**CDD: 657.0285**

Bibliotecário responsável: Elba Lopes, CRB- 8/9622

**JAILSON EVANGELISTA**

**ESTUDO SOBRE A TEORIA DA DOMINÂNCIA TECNOLÓGICA NO USO DA  
INTELIGÊNCIA ARTIFICIAL APLICADA À GESTÃO TRIBUTÁRIA NO BRASIL**

Dissertação apresentada à Fundação Escola de Comércio Álvares Penteado - FECAP, como requisito para a obtenção do título de Mestre em Ciências Contábeis.

**COMISSÃO JULGADORA**

---

**Prof. Dr. Luis Borges Gouveia**  
**Universidade Fernando Pessoa**

---

**Prof. Dr. Matheus Albergaria de Magalhães**  
**Fundação Escola de Comércio Álvares Penteado – FECAP**

---

**Prof. Dr. Tiago Nascimento Borges Slavov**  
**Fundação Escola de Comércio Álvares Penteado – FECAP**  
**Professor Orientador – Presidente da Banca Examinadora**

**São Paulo, 21 de fevereiro de 2020.**

## Dedicatória

À Juliana, aos meus filhos João Victor e Valentina e toda minha família e amigos, por toda demonstração de compreensão e cumplicidade incondicional na realização deste sonho, quando das minhas ausências nos muitos dias de dedicação ao mestrado.

## **Agradecimentos**

Agradeço a Deus pela oportunidade de ter vivido este projeto tão importante na minha vida pessoal e profissional. Esta Dissertação é um tributo à transformação que a área tributária está vivendo, da qual participo há 19 anos.

Agradeço a todos os profissionais que cederam uma fração de seu tempo contribuindo para esta pesquisa e às empresas participantes, pelos documentos disponibilizados. Resta-me um verdadeiro débito de gratidão por toda ajuda recebida.

Agradeço ao meu caro orientador, Prof. Dr. Tiago Slavov, pelo apoio pleno e humano, por sua sabedoria e pela honra de ser seu orientando. Não há palavras para descrever minha gratidão. Por toda ajuda meu professor, muito obrigado!

Aos membros da banca, Prof. Dr. Matheus Albergaria e Prof. Dr. Luis Borges Gouveia, pelo esforço, atenção e importantes contribuições feitas, durante esta jornada, para aprimoramento deste trabalho.

Aos professores do programa de mestrado da Fundação Escola de Comércio Álvares Penteado – FECAP, que se dispuseram a compartilhar seus conhecimentos da melhor forma possível.

Ao professor Fabio Rodrigues, pela disponibilidade de uso da ferramenta do Busca.Legal, bem como pela dedicação de tempo para nossas reuniões de alinhamentos, o que muito contribuiu para evolução deste trabalho.

## Resumo

Evangelista, J. (2019). *Estudo sobre a teoria da dominância tecnológica no uso da inteligência artificial aplicada à gestão tributária no Brasil* (Dissertação de Mestrado). Centro Universitário Álvares Penteado, Fundação Escola de Comércio Álvares Penteado - FECAP, São Paulo, SP, Brasil.

O presente estudo busca investigar a dominância tecnológica no uso da inteligência artificial nas rotinas da área tributária sob a luz da teoria da dominância tecnológica (TTD) desenvolvida por Arnold e Sutton (1998), para as áreas contábil e tributária, analisando o nível de confiança (dominância) dos profissionais nos sistemas com tecnologias. O estudo é composto por quatro partes; a primeira retrata o objetivo, bem como aborda a justificativa do estudo, uma vez que embora a IA já exista à algum tempo, no cenário tributário atual ainda pode ser vista como algo novo, até porque as rotinas ainda são desempenhadas por habilidades técnicas e manuais, diferentemente do fisco que está se modernizando e exigindo uma entrega célere dos dados, criando aqui, com essa desigualdade entre contribuinte e fisco, uma oportunidade de estudo. A segunda parte trata da revisão teórica, onde focamos, além da própria TTD e IA, na especialidade, familiaridade e experiência do profissional tributário com tecnologias. A terceira parte contempla a descrição da metodologia, discorrendo sobre a inferência causal, uma vez que este estudo conclui sobre uma conexão causal com base nas condições da ocorrência de um efeito, bem como aborda a metodologia do quase experimento, já que para aplicação da *survey*, utilizamos deste método, onde 144 profissionais respondentes foram apartados em dois grupos (controle e tratamento). A quarta parte se refere às análises dos resultados, que foram divididas em descritiva e estatística, confirmando a H2 desta pesquisa e, embora as hipóteses 1 e 3 não foram confirmadas estatisticamente, com base na *survey* e nas análises descritivas temos visibilidade do quanto os profissionais tributários brasileiros já entendem a tecnologia como ajuda e a valorizam, isto, claro, não deixando de serem críticos com os resultados, pois são profissionais extremamente técnicos com capacidade para avaliar, criticar e confiar de forma equilibrada. Esta valorização, conseqüentemente, também traz uma reflexão em relação à academia, no que se refere às ementas dos cursos de ciências contábeis.

**Palavras-chave:** Transformação digital. Tributos. Profissional tributário. Inteligência Artificial. Teoria da Dominância Tecnológica. Tecnologia

## Abstract

Evangelista, J. (2019). *Estudo sobre a teoria da dominância tecnológica no uso da inteligência artificial aplicada à Gestão tributária no Brasil* (Dissertação de Mestrado). Centro Universitário Álvares Penteado, Fundação Escola de Comércio Álvares Penteado - FECAP, São Paulo, SP, Brasil.

The present study seeks to investigate the technological dominance in the use of artificial intelligence in the routines of the tax area under the light of the technological dominance theory (TTD) developed by Arnold and Sutton (1998), for the accounting and tax areas, analyzing the level of confidence (dominance) of professionals in systems with technologies. The study consists of four parts; the first portrays the objective, as well as addresses the study's justification, since although AI has been around for some time, in the current tax scenario it can be seen as something new, not least because the routines are still performed by technical and manual skills, unlike the tax authorities that are modernizing and demanding a quick delivery of data, creating here, with this inequality between taxpayers and tax authorities, an opportunity for study. The second part deals with the theoretical review, where we focus, in addition to TTD and AI itself, on the tax professional's expertise, familiarity and experience with technologies. The third part includes the description of the methodology, discussing the causal inference, since this study concludes about a causal connection based on the conditions of the occurrence of an effect, as well as addressing the quasi-experiment methodology, since for the application of the survey, we used this method, where 144 professional respondents were separated into two groups (control and treatment). The fourth part refers to the analysis of the results, which were divided into descriptive and statistical, confirming the H2 of this research and, although hypotheses 1 and 3 were not statistically confirmed, based on the survey and descriptive analyzes we have visibility of how much the professionals Brazilian tax professionals already understand technology as a help and value it, of course, while being critical of the results, as they are extremely technical professionals with the capacity to assess, criticize and trust in a balanced way. This appreciation, consequently, also brings a reflection in relation to the academy, with regard to the menus of the courses of accounting sciences.

**Keywords:** Digital Transformation. Taxes. Artificial Intelligence. Technological Dominance Theory. Technology.



## Lista de Tabelas

Tabela 1 – Fatores Determinantes da TTD.....	31
Tabela 2 – Mensuração da TTD.....	33
Tabela 3 – Proposições da TTD.....	34
Tabela 4 – Hipóteses.....	44
Tabela 5 – Definição de Enigmas.....	52
Tabela 6 – Descrição e métricas das variáveis.....	62
Tabela 7 – Ameaças à validade interna.....	63
Tabela 8 – Validade externa.....	64
Tabela 9 – Análise Demográfica.....	67
Tabela 10 – Constructos versus itens de medição.....	68
Tabela 11 – Estudos Anteriores.....	80

## Lista de Figuras

Figura 1 – Incidência dos Impostos nas operações de compras e vendas de produtos, mercadorias e serviços.....	39
Figura 2 – Delineamento de um quase experimento.....	52
Figura 3 – – Distribuição da dominância para o grupo controle.....	69
Figura 4 – Distribuição da dominância para o grupo de tratamento.....	70
Figura 5 – Média com barras de erros para dominância por grupo: Controle e tratamento.....	70
Figura 6 – Teste de Normalidade.....	71
Figura 7 – Teste de Mann-Whitney - comparação de distribuições.....	72
Figura 8 – Dominância <i>versus</i> Especialização.....	73
Figura 9 – Teste de Two-Way ANOVA – Especialização.....	73
Figura 10 – Dominância <i>versus</i> Familiaridade.....	74
Figura 11 – Teste de Two-Way ANOVA – Familiaridade.....	75
Figura 12 – Dominância <i>versus</i> Experiência.....	76
Figura 13 – Teste de Two-Way ANOVA – Experiência.....	77

<b>Figura 14 – Teste de significância – Variável idade.....</b>	<b>78</b>
<b>Figura 15 – Teste de significância – Variável Senioridade de cargo.....</b>	<b>78</b>
<b>Figura 16 – Teste de significância – Variável Dificuldade (<i>busca por legislação</i>).....</b>	<b>78</b>
<b>Figura 17 – Teste de significância – Grau de participação da IA.....</b>	<b>78</b>
<b>Figura 18 – Teste de significância – Avaliações positivas com uso da IA.....</b>	<b>79</b>
<b>Figura 19 – Teste de significância – Avaliações negativas pelo não uso da IA....</b>	<b>79</b>
<b>Figura 20 – Teste de significância – Avaliação técnica.....</b>	<b>79</b>

## Lista de Abreviaturas e Siglas

<b>AIR</b>	Agente Inteligente Robótico
<b>CEST</b>	Código Especificador da Substituição Tributária
<b>CFC</b>	Conselho Federal de Contabilidade
<b>COFINS</b>	Contribuição para o Financiamento da Seguridade Social
<b>CST</b>	Código de Situação Tributária
<b>DNC</b>	<i>Differentiable Neural Computers</i>
<b>EFD</b>	Escrituração Fiscal Digital
<b>ERP</b>	<i>Enterprise Resource Planning</i>
<b>GPS</b>	<i>Positioning System</i>
<b>IA</b>	Inteligência Artificial
<b>IBM</b>	International Business Machines Corporation
<b>IBPT</b>	Instituto Brasileiro de Planejamento e Tributação
<b>ICMS</b>	Imposto sobre Circulação de Mercadorias e Serviços
<b>ICMS-ST</b> Tributária	Imposto sobre Circulação de Mercadorias e Serviços – Substituição
<b>IDAS</b>	Auxílios inteligentes à decisão
<b>IDC</b>	<i>International Data Corporation</i>
<b>IPI</b>	Imposto sobre Produtos Industrializados
<b>KPI</b>	<i>Key Performance Indicator</i>
<b>MVA</b>	Margem de Valor Agregado
<b>NCM</b>	Nomenclatura Comum do Mercosul
<b>OCDE</b>	Organização para a Cooperação e Desenvolvimento Económico
<b>OAB</b>	Ordem dos Advogados do Brasil
<b>PE</b>	Pernambuco

<b>PIS</b>	Programa de Integração Social
<b>PWC</b>	<i>PricewaterhouseCoopers</i>
<b>SPED</b>	Sistema Público de Escrituração Digital
<b>TTD</b>	<i>Theory of Technology Dominance</i>
<b>WBG</b>	<i>World Bank Group</i>

## Sumário

1	Introdução .....	13
1.1	Contextualização.....	13
1.2	Questão de pesquisa .....	14
1.3	Objetivos.....	16
1.4	Justificativa .....	16
1.5	Contribuições .....	17
1.6	Delimitações .....	18
2	Revisão Teórica.....	19
2.1	Inteligência Artificial - IA.....	19
2.1.1	<i>Agentes Inteligentes</i> .....	22
2.1.2	<i>Machine Learning e Deep Learning</i> .....	23
2.1.3	<i>Inteligência Artificial na área Contábil e Tributária</i> .....	25
2.2	Teoria da dominância tecnológica.....	27
2.3	Experiência e especialidade do profissional tributário .....	33
2.4	Familiaridade com as Novas Tecnologias da Informação e Comunicações.....	35
3	Metodologia.....	44
3.1	Inferência causal.....	44
3.2	Quase experimento .....	45
3.3	Campo de estudo - busca legal .....	48
3.4	Procedimentos metodológicos.....	49
3.4.1	<i>Delineamento do quase experimento</i> .....	49
3.4.2	<i>População e amostra</i> .....	51
3.5	Condução do experimento .....	51
3.5.1	<i>Pré-teste (O<sub>1</sub>)</i> .....	52
3.5.2	<i>Acesso ao software Busca.Legal</i> .....	52
3.5.3	<i>Instrumento de coleta de dados (O<sub>2</sub>)</i> .....	53
3.6	Validade interna e externa.....	60
4	Análises dos Resultados .....	63
4.1	Análise demográfica .....	63
4.2	Estatística descritiva.....	64
4.3	Análise estatística dos dados.....	65
4.3.1	<i>Dominância nos grupos</i> .....	66

<i>4.3.2 Dominância por especialização</i> .....	69
<i>4.3.3 Dominância por familiaridade</i> .....	70
<i>4.3.4 Dominância por experiência</i> .....	72
<i>4.3.6 Testes adicionais</i> .....	73
<i>4.3.7 Comparação com resultados anteriores</i> .....	75
<b>5 Conclusões</b> .....	79
<b>Referências</b> .....	83
<b>Apêndice A – Termo de Consentimento Livre e Esclarecido</b> .....	92
<b>Apêndice B - Instrumentos de Coleta de Dados</b> .....	93
<b>Apêndice C – Gabarito das Questões Alternativas</b> .....	99

## 1 Introdução

### 1.1 Contextualização

Estudos recentes (Abbott & Bogenschneider, 2018; Askary, Abu-Ghazaleh, & Tahat, 2018, Hemberg, Rosen, Warner, Wijesinghe, & O'Reilly, 2016; Issa, Sun, & Vasarhelyi, 2016; Kokina & Davenport, 2017; Marshall & Lambert, 2018; Sun & Vasarhelyi, 2018) destacam a relevância do uso da Inteligência Artificial – IA para transformar processos de preparação e análise de informações contábeis e fiscais, inclusive no Brasil (Felipe & Perrota, 2018; Souza, 2014).

O uso de tecnologias da informação e comunicações para combater a sonegação no Brasil, com a publicação do Decreto 6.022 em 2007, que instituiu o Sistema Público de Escrituração Digital – SPED, representou a inserção do governo e demais autoridades fiscais numa realidade marcada pelo alinhamento das novas tecnologias e aprimoramento das habilidades humanas, tanto no processo de geração de riqueza como em sua mensuração (Guerra & Gouveia, 2018). Souza (2014) ressalta que, com o SPED, o fisco brasileiro tem servido de referência para outros países ao transformar documentos e livros impressos em arquivos eletrônicos (informações digitais) e permitir ao contribuinte, por exemplo, a automação de grande parte do processo de escrituração fiscal.

Krahel e Titera (2015) ressaltam, contudo, que a adoção de tecnologias digitais por parte da administração tributária tem proporcionado um desequilíbrio entre o desejo do fisco de obter mais informações e o custo para preparar e transmitir essas informações. Se antes os contribuintes eram forçados a gerenciar uma escassez de informações, agora são forçados a lidar com enormes volumes de dados e metadados que ocupam petabytes de espaço em seus servidores. O problema é destacado no estudo do World Bank Group (WBG) e PricewaterhouseCoopers (PWC) (2018), denominado *Paying Taxes 2018*, que constatou que, no mundo todo, a transição para relatórios fiscais em tempo real está aumentando os custos para os contribuintes, que têm que cumprir mais requisitos e gerir riscos associados ao fornecimento de maiores volumes de dados para as autoridades fiscais.

Neste sentido, Furlan e Laurindo (2017) ressaltam que o crescimento do volume de dados (Big Data) apresentados ao fisco fez crescer, também, o desenvolvimento de novas soluções e tecnologias para auxiliar na tarefa de geração de dados. Por exemplo, Sistemas Integrados de Gestão (*Enterprise Resource*

*Planning, ERP*) são hoje auxiliados por recursos de IA com enfoque na conformidade tributária.

A IA, definida por Kokina e Davenport (2017) como a automatização da inteligência humana, é uma aliada para o gerenciamento e análise de muitos dados, automatizando num primeiro momento rotinas repetitivas e, depois, o processo analítico, tudo via algoritmos e padrões de críticas. Segundo Warner et al. (2015), o uso da IA é necessário para alcançar precisão e a confiabilidade desejadas nas operações fiscais no mundo todo. Os autores evidenciam, por exemplo, o uso de algoritmos por parte das administrações tributárias para ajudar a prever a evasão fiscal e, assim, definir políticas de gestão tributária.

No entanto, como observam Kolbjørnsrud, Amico e Thomas (2017), o fator humano ainda é decisivo para o sucesso das implementações de IA nas organizações, especialmente no que se refere à confiança na tecnologia. Desta forma, entender o comportamento dos profissionais tributários diante das tecnologias de informação e comunicação é um tema relevante para as organizações.

## 1.2 Questão de pesquisa

O problema do presente estudo é: **A experiência, especialização e familiaridade de profissionais tributários com tecnologias da informação afeta sua confiança em ferramentas com inteligência artificial?**

Estudos da década de 1950 já descreviam as implicações práticas da IA em tarefas automatizáveis desenvolvidas pelo homem (Minsky, 1961), mas a pesquisa aplicada à área contábil e tributária sempre foi incipiente, com uma certa concentração de trabalhos publicados no início dos anos 1990 (Chase & Shim, 1991; Meservy, Denna, & Hansen, 1992; O'Leary, 1991) e uma retomada das discussões sobre o assunto nos últimos anos (Abbott & Bogenschneider, 2018; Askary et al., 2018; Hemberg et al, 2016; Issa et al., 2016; Kokina & Davenport, 2017; Marshall & Lambert, 2018; Sun & Vasarhelyi, 2018). No Brasil, além do trabalho de Souza (2014), que abordou o uso da IA no ensino da contabilidade, mas não nas rotinas contábeis em si, não foram localizados estudos abordando, ao menos explicitamente, as implicações da IA na Contabilidade. Sobre o tema tributos, trabalhos nacionais que abordaram o uso da IA (Macarini, 2017; Porto, 2017) trataram do seu uso na área pública, mas não no ambiente empresarial.



O'Leary (1991) já afirmava que o uso da IA poderia ser útil para mitigar dificuldades no gerenciamento de informações, de tal forma que o conceito é relevante para facilitar a organização e armazenamento de bancos de dados, sendo um elemento-chave para a racionalização de organizações, sociedades e economias inteiras. Um exemplo dessa proposta pode ser verificado no estudo de Marshall e Lambert (2018), ao apresentar um caso hipotético de construção de um modelo computacional cognitivo baseado em IA para suporte nas tarefas contábeis. Segundo o autor, o tema evidencia a necessidade de investigação dos papéis dos profissionais na utilização de sistemas de IA, em que se avaliem às mudanças organizacionais nos modelos de gestão focados nessa tecnologia, por exemplo, sobre o aprimoramento do conhecimento e das habilidades humanas, o aumento do desempenho das tarefas com a redesignação para tarefas de maior valor organizacional e a satisfação no trabalho das pessoas que interagem com essa tecnologia.

No contexto da questão de pesquisa, Kokina e Davenport (2017) alertam para a necessidade de investigação dos vieses da IA, que tendem a criar preconceitos nos humanos que criam tais ferramentas ou com elas interagem. Segundo os autores, o primeiro viés é o viés de dados, que está associado com os sistemas que geram resultados tendenciosos por causa de falhas ou de assimetria nos dados subjacentes. Outro viés é o viés por meio da interação que ocorre quando as máquinas aprendem/replicam/absorvem os preconceitos das pessoas que as treinam. O terceiro viés ocorre quando as máquinas protegem os seres humanos de pontos de vista conflitantes, fornecendo-lhes informações que confirmam suas preferências ou crenças. Finalmente, um último viés ocorre como resultado de estereótipos dos usuários em relação à tecnologia.

A preocupação de Kokina e Davenport (2017) vai de encontro com Sutton, Holt e Arnold (2016), ao observar que, se por um lado, avanços substanciais da IA estão sendo feitos na área de processamento de linguagem natural, como evidenciado em nossa vida cotidiana por tecnologias móveis e pela interação com robôs como a Siri da Apple ou a Cortana da Microsoft (Brynjolfsson & McAfee, 2014), a preocupação com os efeitos prejudiciais da tecnologia na profissão contábil também deve receber atenção de estudos na área. Nesse sentido, Masselli, Ricketts, Arnold e Sutton (2002) investigaram o uso de IA para conformidade tributária, avaliando os problemas da adoção da tecnologia com base em princípios daquela que passou a ser denominada Teoria da Dominância Tecnológica (*Theory of Technology Dominance - TTD*),

bastante difundida em estudos organizacionais, inclusive na área contábil (Arnold & Sutton, 1998; Arnold, Collier, Leech, & Sutton, 2004; Axelsen, 2012; Hampton, 2005; Malaescu & Sutton, 2015; Noga & Arnold, 2002).

Assim, a IA oferece um relevante cenário de transformação dos processos tributários nas empresas. Os benefícios potenciais do uso da IA na gestão tributária, especialmente, no caso brasileiro, ainda são pouco explorados pela academia, assim como os riscos. Dentre os riscos, a mudança no perfil e comportamento dos profissionais da área é algo destacado na literatura recente. A TTD indica, por exemplo, que usuários iniciantes podem não ter a experiência para interagir corretamente com os recursos de IA, enquanto usuários experientes podem se recusar a confiar nas recomendações dessas tecnologias (Jensen et al, 2010), dentre outros desafios.

### **1.3 Objetivos**

O objetivo principal da pesquisa é investigar se a experiência, a especialização e a familiaridade do profissional tributário brasileiro com novas tecnologias afetam sua confiança nos sistemas de IA.

Como objetivos específicos, o estudo pretende:

- a) Compreender o papel da IA na rotina tributária das organizações empresariais brasileiras;
- b) verificar se o uso de IA, nas rotinas tributárias, direciona o profissional da área a buscar ao aprimoramento das suas competências profissionais;
- c) identificar a percepção do profissional em relação à eficiência de rotinas tributárias pós-implementação de ferramentas que fazem uso de/ baseadas em IA e seus benefícios.

### **1.4 Justificativa**

Segundo estudo da KPMG (2016), a inserção de tecnologia mais avançada, como a IA, no cenário tributário atual é algo que pode ser considerado ainda novo, pois ao mesmo tempo em que as companhias veem a necessidade dessa atualização, as rotinas ainda são desempenhadas, em sua grande maioria, pelo emprego de habilidades técnicas e manuais. Inclusive, boa parte dos treinamentos envolvendo a área fiscal se concentram, ainda, em competências funcionais e técnicas, dando

tratativas de fluxos e rotinas com início, meio e fim no que se refere a fechamentos fiscais e envio de obrigações acessórias.

Assim, o profissional tributário precisa se adequar para entender este novo cenário, sendo que a adequação necessária já não é mais exclusivamente técnica, mas engloba a visão de um conjunto de operações com seus impactos, seus alcances e seus resultados nas competências e julgamento profissional (Passos, 2011).

Krahel e Titera (2015) afirma que essa mudança nos padrões de concentração em dados e nos processos que os geram e sua análise, em vez de sua simples apresentação, agregam valor e relevância ao profissional tributário, além de capacitar usuários e melhorar a eficiência do mercado de capitais.

### **1.5 Contribuições**

Para as empresas, o presente estudo oferece visibilidade da relação entre o gerenciamento de muitas informações tributárias com uso de IA e, ao agregar eficiência ao *compliance*, uma potencial diminuição de gastos com custos de conformidade tributária, que, no Brasil, segundo Miyoshi (2012), são custos relacionados às soluções para auxiliar no envio das obrigações acessórias dispostas pela legislação, assim como os custos necessários para minimizar erros e possíveis autuações fiscais.

O estudo contribui para melhorar a percepção do mercado em relação ao impacto do uso da IA pelo profissional tributário, oferecendo uma análise da preparação dos profissionais para o incremento da automação tributária, bem como verificar a qualidade das análises após a implementação de ferramentas que utilizam IA, de forma que o presente trabalho irá além da literatura consultada, já que o questionário de teste será aplicado à profissionais corporativos, diferenciando-se de estudos anteriores, cujos experimentos foram conduzidos em ambiente acadêmico e não profissional.

O estudo também oferece um conjunto de recomendações relacionadas ao *Compliance* Tributário, considerando que os cruzamentos de análises, tendo como recurso a IA, podem ser mais ágeis e precisos, pois além de contemplar o exame de grandes volumes de informações, tornando-as mais estratégicas e seguras, tornam as apurações de impostos e decisões tributárias menos burocráticas e mais assertivas. Por fim, o trabalho pretende orientar sobre a necessidade de atualização em relação às tecnologias da informação e comunicações para as rotinas tributárias,

bem como a necessidade de aptidão do profissional tributário para o novo mercado, que requer o cumprimento das exigências da lei, mas com agilidade e sensibilidade estratégica, com foco no processo decisório.

Em relação à academia e pesquisas científicas, o estudo contribui para a comprovação da Teoria da Dominância Tecnológica - TTD, utilizando o ambiente de tributação brasileira, considerado um dos mais complexos do mundo, segundo o Relatório de Estudos Econômicos da Organização para a Cooperação e Desenvolvimento Económico [OCDE] (2018).

## **1.6 Delimitações**

Estudos já publicados sobre Inteligência Artificial aplicada à gestão tributária em geral estão relacionados à criação de ferramentas de verificação cruzada (*cross checking*) dos dados tributários, quer anterior ou posterior à fiscalização (Cilliers, 2017), o que não tem alcance no presente estudo, que limita-se a analisar as experiências vividas em relação à eficiência do *compliance*, não alcançando os aspectos relacionados ao *design* da ferramenta de IA.

## 2 Revisão Teórica

Arnold (2018) observa que os investidores e empresários sempre esperaram pacientemente relatórios contábeis trimestrais e anuais, porém a IA vem mudando a maneira como as pessoas aguardam, acessam e usam informações. Segundo o autor, a IA vem atraindo atenção dos gestores de tributos por possibilitar a entrega eficaz de resultados. Por outro lado, Axelsen (2012) afirma que há uma preocupação quanto à qualificação dos profissionais na gestão tributária das organizações em vista do uso continuado da inteligência artificial, de forma que habilidades e conhecimentos técnicos parecem não ter mais o mesmo valor na tomada de decisão. Essa dicotomia revela a necessidade de investigação que verifique se a capacidade técnica de um profissional ainda é de grande relevância na gestão tributária, no sentido de se compreender como a complexidade das regras tributárias organizadas por IA desqualifica o profissional em sua posição dentro de uma organização.

Neste capítulo estão descritos os elementos teóricos sobre IA, bem como seus impactos no que se refere à competência do profissional de tributos nas organizações empresariais.

### 2.1 Inteligência Artificial - IA

Com início nos anos 1940, a pesquisa em torno da IA explorava novas funcionalidades para o computador, ainda em projeto. Com o passar do tempo, surgiram várias linhas de estudo da IA, entre elas a biológica, dedicada ao desenvolvimento de conceitos que pretendiam imitar as redes neurais humanas, de forma que em meados de 1960 pesquisadores dessa linha acreditavam ser possível máquinas realizarem tarefas humanas complexas, como raciocinar. Depois de um período de poucas pesquisas e implementações, os estudos sobre redes neurais voltaram à tona nos anos 1980, mas é nos anos de 1990 que a pesquisa em IA tem um grande impulso, consolidando-se verdadeiramente como a base dos estudos (Issa et al., 2016; Marar, Carvalho & Vasconcelos, 1996).

Segundo McCarty (1976), a IA encontra-se em uma área da ciência da computação em que os pesquisadores buscam realidades diferentes de um modelo simplesmente programático. Não para resolver problemas simples, como adição de dois números, mas para criar uma espécie de *pensamento* na computação. A área é dividida em duas partes: inteligência artificial simbólica, ligada à psicologia; e a inteligência artificial conexionista, ou redes neurais artificiais, que vem da

neurofisiologia. Essa última é hoje citada pelo Google ao explicar, por exemplo, o funcionamento do robô de IA *DeepMind* treinado para jogar Go (Arnold, 2018)

O que se conhece hoje como inteligência artificial foi detalhado pelo professor John McCarthy, da Universidade de Stanford, que começou a usar o termo em uma conferência na Faculdade de Dartmouth, New Hampshire, em 1959. Como na época já existiam várias teorias de complexidade, simulação de linguagem, redes neurais e máquinas de aprendizagem, ele resolveu dar o nome de inteligência artificial para esses sistemas de imaginação humana que usam a ciência da computação. A capacidade e a funcionalidade eletrônica dobravam a cada 18 meses, um crescimento quase exponencial praticamente ininterrupto, de modo que os participantes do congresso saíram de lá crenes de que, um dia, os computadores conseguiriam ser tão inteligentes quanto os humanos, o que contribuiu para que McCarthy conseguisse grandes avanços em seu laboratório, um dos primeiros dedicados ao desenvolvimento da inteligência artificial (McCarthy, 1976).

Antes de McCarthy, Turing (1937) já estudava a possibilidade de uma máquina pensar como humano e criou o teste de Turing, que avalia se a percepção daquele que interage com uma máquina é capaz de identificar se seu interlocutor se trata de um ser humano ou de inteligência artificial e não de um homem. Meservy et al. (1992) chegaram a documentar o teste em tecnologias tributárias, comprovando a hipótese de que era possível identificar.

Em termos operacionais, a IA atualmente é um ramo da ciência da computação que se propõe a elaborar dispositivos que simulem a capacidade humana de raciocinar, tomar decisões e resolver problemas, enfim, a capacidade de ser inteligente. É uma mistura de software e equipamentos, como um substituto para a inteligência humana, permitindo resolver problemas de negócios complexos por meio de raciocínio, aprendizado e reconhecimento de padrões iguais aos dos seres humanos (Marshall & Lambert, 2018).

A IA funciona a partir de uma programação prévia, um código que considera variáveis, processa os dados e determina o que fazer em cada situação. Realiza tarefas muitas vezes muito complexas, resolvendo problemas com milhares de variáveis em vez de apenas uma. Necessita de algoritmos, que são uma sequência de instruções que orientam o funcionamento de um software e, com isso, utiliza-se da ciência da computação, que estuda técnicas e métodos de processamento de dados e tem o desenvolvimento de algoritmos uma de suas questões centrais. Os

profissionais envolvidos são, costumeiramente, da área de tecnologia da informação com formação em ciências da computação, dentre outros profissionais de áreas distintas, com foco em alguma ferramenta específica (Askary et al., 2018).

Várias atividades empresariais atualmente utilizam a IA. O *Global Positioning System* (GPS), por exemplo, aponta o melhor caminho por meio da IA, que interpreta dados fornecidos automaticamente por outros usuários sobre o tráfego nas vias. Centrais de atendimento ao usuário de grandes empresas utilizam *Chatbots* e sistemas com processamento de linguagem natural para substituir atendentes humanos e estão à disposição dos usuários para resolução de dúvidas 24 horas por dia. O varejo *online* utiliza algoritmos de lojas virtuais que reconhecem padrões de compras de usuários para apresentar a eles ofertas de acordo com suas preferências. O jornalismo possui aplicações de IA capazes de redigir matérias jornalísticas informativas de tal modo que torna difícil para o leitor distingui-las de textos escritos por humanos. Os bancos utilizam algoritmos para analisar dados do mercado, gerenciar finanças e se relacionar com seus clientes. O direito conta com robôs para realizar, de forma mais rápida, precisa, direta e acessível do ponto de vista econômico, muitos trabalhos outrora manuais. E ainda podemos citar outras funcionalidades como Siri da Apple, carros autônomos, dispositivos IoT como Rachio e a pesquisa adaptativa do Google. (Askary et al., 2018).

Dentre os exemplos apresentados, Floridi (2017) mostra que até uma área essencialmente técnica, como a saúde, é afetada pela mudança, sendo que soluções de IA estão se tornando aliadas de enfermeiros, médicos, assistentes sociais, técnicos e especialistas, por exemplo, radiologistas, ajudando no desempenho de atividades, que, há poucos anos, eram consideradas fora de alcance para a intervenção tecnológica, como catalogar imagens, sugerir diagnósticos, monitorar e até mesmo mover pacientes, interpretar radiografias, controlar bombas de insulina, extrair novas informações médicas de grandes conjuntos de dados e assim por diante. Segundo a literatura, as tarefas baseadas em IA são atualmente determinadas, especialmente, por dois elementos que interagem entre si: agentes inteligentes e modelagem de resolução de problemas (baseados em *machine learning* ou *deep learning*, por exemplo).

### 2.1.1 Agentes Inteligentes

No contexto de IA, segundo Russel e Norvig (2016), um agente inteligente é um indivíduo robótico ou humano, que tenha capacidade de perceber seu ambiente através de sensores e atuar sobre esse ambiente por meio de efeitos. Um agente humano tem olhos, ouvidos e outros órgãos para atuar como sensores e mãos, pernas, boca e outras partes do corpo para provocar os efeitos. Um agente robótico, por exemplo, utiliza câmeras e localizadores de infravermelho como sensores, e vários motores para gerar os efeitos, enquanto um agente de software codifica cadeias de *bits* como suas percepções e ações, de forma que se possa repeti-las. Potencialmente, um agente inteligente deve conseguir fazer a coisa certa, que pode ser definida como aquela que é eficaz e eficiente, ainda que seja necessário decidir como e quando avaliar o sucesso do agente, bem como a forma de medição de desempenho.

Assim, os agentes inteligentes simples podem ser representados por profissionais menos experientes, com menor capacidade de planejar as ações com antecedência. Além disso, tais profissionais podem não ter conhecimento do impacto e reflexo de suas decisões nem compreender o que estão tentando alcançar com tais ações. No outro lado estariam os agentes mais sofisticados, com mais experiência, os quais resolvem os problemas de forma mais prática e assertiva.

Em um cenário de decisões complexas, um agente inteligente robótico (AIR) baseado em Inteligência Artificial decide o que fazer encontrando sequências de ações que levam a estados, sendo possível interagir com um ser humano, que pode formular uma visão mais apropriada do problema, principalmente quando o tipo de problema em questão depende de conhecimento disponível apenas ao interlocutor humano. Neste sentido, segundo Russel e Norvig (2016), o processo de solução pode ser resumido em quatro diferentes estratégias:

- a) Completude: a estratégia é garantida para encontrar uma solução quando existe uma?
- b) Tempo: quanto tempo leva para encontrar uma solução?
- c) Espaço: quanta memória é necessária para realizar a busca pela solução?
- d) Otimalidade: a estratégia encontra a solução da mais alta qualidade quando existem várias soluções diferentes?



Os agentes inteligentes robóticos, embora com capacidade de perceber seu ambiente por meio de sensores e atuar sobre esse ambiente por meio de efeitos, necessitam ainda de outros suportes tecnológicos, como o *Machine Learning* e *Deep Learning*, para aprender e extrair a informação desejada dentre dados volumosos

### **2.1.2 Machine Learning e Deep Learning**

Para Miller (2019), *Machine Learning* é a prática de usar algoritmos para coletar dados, aprender com eles, e então fazer uma determinação ou previsão sobre alguma coisa no mundo. Então, em vez de implementar as rotinas de software manualmente, com um set específico de instruções para completar uma tarefa em particular, a máquina é “treinada” usando uma quantidade grande de dados e algoritmos que dão e ela a habilidade de aprender como executar a tarefa. O conceito é formado a partir da abordagem de algoritmos com árvore de aprendizado, programação lógica indutiva, agrupamento, aprendizado reforçado, redes Bayesianas, entre outros promotores da disseminação de implantação de IA no mundo.

Para Yang, Chuang e Kuan (2019), o uso do *machine learning* nas mais diversas aplicações só tendem a crescer, pois muitos recursos tecnológicos que temos hoje só funcionam ou são viáveis por conta da inteligência artificial, via *machine learning*:

- a) banco de dados autônomo: com auxílio do *machine learning*, bancos lidam de modo automatizado com várias tarefas até então realizadas por um administrador e diminuindo o risco de indisponibilidade da aplicação por falha humana;
- b) combate a fraudes em sistemas de pagamento: diversas tentativas de fraude com cartões de crédito e outros meios de pagamento ocorrem a cada segundo no mundo todo; felizmente, o *machine learning* tem permitido que sistemas de combate a fraudes barrem a maior parte dessas ações;
- c) tradução de textos: uma tradução nunca pode ser feita ao pé da letra – é preciso levar em conta contextos, expressões regionais e outros parâmetros, e o *machine learning* tem aperfeiçoado a precisão dos tradutores automáticos;
- d) recomendação de conteúdo: plataformas de vídeo e áudio usam o *machine learning* para analisar o histórico de conteúdo reproduzido ou rejeitado pelo usuário para dar a ele recomendações condizentes com suas preferências.

Já o *Deep Learning*, segundo Frawley, Paitetsjy-Shapiro e Matheus (1992), é uma das bases da IA e um meio para aperfeiçoamento do *Machine Learning*. O conceito é formado por métodos de representação-aprendizagem com múltiplos níveis de representação, obtidos pela composição de módulos simples, mas não lineares, que transformam a representação em um nível (começando com a entrada bruta) em uma representação em um nível mais alto, um pouco mais abstrato. Com a composição suficiente, tais transformações – funções muito complexas – podem ser aprendidas.

Para tarefas de classificação, camadas superiores de representação amplificam aspectos do *input* que são importantes para a discriminação e suprimem variações irrelevantes. Uma imagem, por exemplo, vem na forma de uma matriz de valores de pixel, e os recursos aprendidos na primeira camada de representação, tipicamente, indicam presença ou ausência de bordas em orientações e locais específicos na imagem. A segunda camada normalmente detecta motivos analisando arranjos particulares de bordas, independentemente de pequenas variações nas posições das bordas. A terceira camada pode agrupar motivos em combinações maiores, que correspondem a partes de objetos familiares, e camadas subsequentes detectariam objetos como combinações dessas partes.

Para Frawley et al. (1992), o aspecto chave do *Deep Learning* é que as camadas de recursos não são projetadas por engenheiros humanos: elas são aprendidas a partir de dados, como por exemplo:

- a) compreensão do comportamento do cliente: realizado por sites de e-commerce robustos (*Amazon e eBay*). Durante todo o tempo no site, os dados do consumidor são coletados. Quanto maior a experiência no local, maiores serão as chances de efetivar a compra. Assim, o site é otimizado a cada acesso por meio dos dados gerados, para que a experiência para aquele cliente seja mais envolvente;
- b) reconhecimento facial: essa aplicação já é utilizada em sites de redes sociais, como o Facebook, para identificar quais são os potenciais usuários a serem marcados em uma determinada foto, e atualmente tem sido bastante utilizada também em sistemas de segurança;
- c) suporte técnico personalizado: torna desnecessária, em muitos casos, a existência de atendentes humanos para prestar o serviço de assistência

remota a um cliente. Alguns exemplos são a Clara, o Howdy e o GridSpace Sift;

- d) carros autônomos: por meio de um Computador Neural Diferenciável (Differentiable neural computers - DNC), ao ser apresentado a mapas, linhas e paradas, o carro consegue se conduzir por uma rota mais curta, facilitando as viagens.

Assim, estes dois mecanismos reforçam a interatividade da ferramenta de IA na vida cotidiana das pessoas, o que não difere muito da imersão destas tecnologias nas rotinas contábeis e tributárias e, neste sentido, Ghahramani (2015) reforça que, com a velocidade das máquinas hoje em dia, a possibilidade de fazer combinações de forma mais rápida que o cérebro humano já é uma realidade.

### **2.1.3 Inteligência Artificial na área Contábil e Tributária**

O objetivo principal da pesquisa é investigar a relação entre a experiência, a especialização e a familiaridade com novas tecnologias e a dependência da utilização de sistemas de IA em profissionais que atuam na gestão tributária. A esse respeito, Didimo, Giammininni, Liotta, Montecchiani e Pagliuca (2018) observam que, até 2020, a maioria das rotinas fiscais utilizarão IA para a tomada de decisões estratégicas e o correto cumprimento das obrigações fiscais principais e acessórias. Levando em consideração todas as regras fiscais e tributárias existentes hoje no Brasil, a aplicação da IA em uma automação fiscal permitiria/possibilitaria analisar informações e estabelecer padrões quase em tempo real, mostrando qual o melhor caminho a seguir, além de garantir às empresas mais segurança e agilidade em seus processos, melhorando assim sua capacidade de análise de dados, segurança da informação e *compliance*.

Barros (2005), em seu estudo sobre o enfoque da informação contábil, entende que, para as decisões tributárias, os sistemas de inteligência artificial têm potencial para o processamento de dados ou de transações rotineiras, para a resolução de problemas simples e até mesmo para suporte às decisões gerenciais tributárias mais complexas, como a análise de planejamento tributário. Sutton et al (2016), retratam que, embora ainda em constante crescimento e de certa forma ainda lenta, a IA permite uma grande mudança nas áreas contábil e tributária, como se demonstra em estudos científicos desenvolvidos nessas áreas.

Por exemplo, depois de introduzir algumas técnicas básicas de processamento de informação semântica desenvolvidas no campo da IA, McCarty (1976) descreveu o que seria a primeira aplicação de IA na gestão tributária, denominada *Taxman*, que utilizava técnicas que permitiam ao computador decidir sobre situações reais na área tributária das empresas. Em um experimento específico, McCarty analisou um caso de uma reorganização societária determinando o efeito tributário da reorganização com base na codificação de vários parâmetros da legislação tributária à época, desenhando um modelo semântico para a decisão que apresentava menor efeito tributário, e então comparou o resultado obtido com a resposta de advogados tributários. Embora o saldo do experimento tenha sido positivo, ou seja, o modelo baseado em IA apresentou resultados melhores que as opiniões dos profissionais consultados, o autor destacou a dificuldade de atualização da jurisprudência como uma restrição para uso massificado do modelo. Atualmente, tal dificuldade poderia ser superada, por exemplo, com a utilização de *Machine Learning*.

Já O'Leary e O'Keefe (1997) analisaram o impacto de IA em questões organizacionais nas rotinas tributárias por meio da metodologia sociológica de Perrow (1967), que desenvolveu uma teoria de análise comparativa do comportamento organizacional, sugerindo que as organizações sejam vistas principalmente como sistemas de trabalho. Assim, Perrow considera a tecnologia como uma variável independente que influencia a organização do trabalho. Ou seja, diferentes formas de tecnologia impactam a maneira como o trabalho é feito. O questionário aplicado a profissionais tributários apresentou perguntas como:

- a) a IA aumentou ou diminuiu o acesso à alta gerência?
- b) a IA reduziu ou aumentou a necessidade de supervisão técnica ou gerencial para lidar com ocorrências excepcionais?
- c) o profissional é capaz de lidar com uma gama maior ou menor de problemas com o sistema após a implementação da IA?

O estudo mostrou um impacto positivo da IA, principalmente em relação a melhoria na produtividade.

González e Velásquez (2013) evidenciaram a adoção da IA na área fiscal com foco em fraudes praticadas por contribuintes chilenos, usando algoritmos de *clustering*, que é um método de aprendizado não supervisionado e *neural gás*, que é um algoritmo para representações de dados com base no recurso de vetores, também usado para identificar grupos de comportamento similar no universo de pessoas e

objetos. Somados a estes, os autores analisaram ainda as árvores de decisões, redes neurais e redes bayesianas, as quais são usadas para identificar as variáveis que estão relacionadas ao ponto que se investiga. O experimento demonstrou que a IA poderia detectar padrões de comportamento associado a fraudes, bem como estabelecer em que medida ou classificação estava o processo de fraude.

Neste mesmo sentido, outros trabalhos (Hemberg et al, 2016; Llacer, Miguel, Noguera & Tapia, 2013; Tabandeh, Jusoh, Nor, & Zaid, 2012; Warner et al., 2015) também pesquisaram o uso da IA na gestão tributária, mas por parte da administração pública, ou seja, não investigaram a IA no ambiente corporativo, que é o foco do presente trabalho.

Assim, com a massificação das implementações de tecnologias nas rotinas fiscais, começam a surgir estudos que priorizam a análise da relação de causa e efeito homem-máquina, buscando entender a aceitação ou dependência da tecnologia (Ghahramani, 2015). Logo, como muitos profissionais têm dificuldade para entender e aceitar a aplicação da IA em suas rotinas, sintetizar como uma máquina pode ser influenciada pela experiência humana e vice-versa passou a ser um campo de investigação das teorias sobre aceitação da tecnologia, como a TTD, explicada na próxima seção.

## **2.2 Teoria da dominância tecnológica**

São muitas as fases que uma organização precisa percorrer antes de incorporar novas ideias ou tecnologias. McFarlan, McKenney e Pyburn (1983) defendem que o processo de difusão de tecnologias da informação e comunicação passa ao menos por quatro etapas:

- a) identificação e investimento em tecnologia – ênfase na aprendizagem e aplicação da nova tecnologia, sendo uma fase em que a experiência com a tecnologia é tão limitada que os participantes não conseguem perceber as implicações a longo prazo.
- b) experimentação, aprendizagem e adaptação – ênfase na sensibilização do usuário para a nova tecnologia e os problemas que ela pode resolver por meio de experiências adquiridas.
- c) racionalização e controle gerencial – ênfase na busca de eficiência a curto prazo, com adoção de novos projetos de uso da tecnologia.

- d) transferência generalizada de tecnologia – ênfase nos benefícios e disseminação para outras unidades dentro da organização.

Segundo McFarlan et al. (1983), para que a evolução da primeira à última etapa ocorra, é necessário que os gestores se antecipem aos potenciais problemas da difusão da adoção de novas tecnologias. E um dos problemas apontados pelos autores é a confiança dos profissionais nas novas tecnologias, sendo que estudos revelam diferentes fatores inibidores ou capacitadores dessa confiança. Esses fatores incluem confiança nas próprias habilidades (Peterson & Pitz, 1986; Whitecotton, 1996), desempenho sob pressão (Ashton, 1990), redução do esforço cognitivo (Todd & Benbasat, 1999), experiência prévia com o auxílio à decisão (Taylor & Todd, 1995), interação com o auxílio à decisão (Kasper, 1996; Whitecotton & Butler, 1998) e especialização do profissional (Mackey & Elam, 1992).

Partindo desses constructos, Arnold e Sutton (1998) desenvolveram a Teoria da Dominância Tecnológica, usando uma abordagem dedutivo-analítica aplicada à tecnologia da informação nas áreas contábil e tributária, que analisa o nível de confiança dos profissionais nos sistemas e ferramentas tecnológicas, como é o caso da IA. Hampton (2005) defende a Teoria destacando que o seu principal objetivo é esclarecer como um profissional, tomador de decisão, pode ou não se tornar dependente de um agente inteligente robótico, baseado em IA, por exemplo, e como esta dependência está relacionada com o grau de confiança no agente inteligente robótico. São duas as principais premissas da confiança na IA:

- a) quando a experiência do usuário é baixa; e
- b) quando a experiência do usuário, a complexidade da tarefa, a familiaridade com o agente inteligente e os ajustes cognitivos são altos.

Ferramentas como a IA são amplamente utilizadas em uma variedade de ambientes de trabalho e oferecem benefícios aos profissionais tomadores de decisão, como na gestão tributária (Noga & Arnold 2002). No entanto, de acordo com Arnold & Sutton (1998), duas etapas críticas devem ocorrer para que o usuário confie nas recomendações de um AIR e delas se beneficie:

- a) o usuário deve aceitar a intervenção do AIR e;
- b) o usuário deve incorporar as recomendações do AIR ao seu processo de tomada de decisão.

Se ambas as etapas forem seguidas, a decisão resultante é frequentemente superior à decisão tomada sem auxílio do AIR. Neste contexto, Arnold e Sutton (1998)

definem a dependência como um apoio no processo de tomada de decisão do profissional e de que ela exerce alguma influência sobre os resultados da decisão. Embora a TTD ofereça um modelo de estudo, o construto de confiança em tecnologia é bastante complexo e incorpora muitas situações, que podem representar/indicar desde confiança excessiva até confiança insuficiente (Arnold & Sutton 1998; Arnold et al. 2004; Hageman 2010; Jones & Wright 2010; Masselli et al. (2002).

Nesse sentido, Arnold e Sutton (1998) ressaltam que a confiança em uma decisão baseada em AIR constitui a base para a TTD, porém a estrutura geral da teoria é maior e compreende três etapas:

a) Identificar fatores determinantes em relação à confiança que um profissional pode ter em decisões apoiadas por AIR. Mesmo que o profissional faça a opção por considerar a sugestão da IA, por exemplo, é necessário que ele possa enxergar o valor da escolha, de forma que ele reconheça que sua experiência, seja por sua especialidade ou familiaridade em relação à tarefa, é válida no processo, bem como que sua decisão também foi considerada/levada em conta, conforme Tabela 1.

Tabela 1  
**Fatores Determinantes da TTD**

Fatores	Conceito
Experiencia da Tarefa	O nível de experiência que um profissional tem em relação à conclusão de uma tarefa, bem como a extensão em que este profissional desenvolveu estratégias para concluir essa tarefa em particular.
Especialidade na Tarefa	Até que ponto as habilidades cognitivas do profissional são desafiadas com o preenchimento de uma determinada tarefa.
Familiaridade do auxílio à decisão	Até que ponto o profissional está confortável com o auxílio de decisão inteligente com base na experiência anterior e / ou treinamento significativo com o auxílio (ou auxílios similares).

*Nota.* Adaptado de “*The theory of technology dominance: Understanding the impact of intelligent decision aids on decision maker’s judgments*”. de Arnold, V., & Sutton, S. G. (1998).

b) Analisar as circunstâncias que podem levar o profissional a confiar em grau indevido nas recomendações do AIR, reforçando o domínio da tecnologia. A falta de experiência e familiaridade, em determinadas operações, pode fazer com que o profissional não conteste a sugestão inteligente, de forma a não se precaver se houve falha na resposta em detrimento de falhas na pergunta. Como exemplo, um trajeto indicado pelo GPS pode indicar um caminho por uma região perigosa ou intransponível.

c) Examinar os efeitos a longo prazo na competência dos profissionais que usam o AIR, bem como medir a evolução do conhecimento de domínio tecnológico, visto que se aderida e com um grau de confiança alto, é tendencioso que o profissional deixe de se manter atualizado e conhecedor da rotina.

Sob essa ótica de aferição, a TTD oferece visibilidade da aceitação da tecnologia, bem como dos impactos na rotina tributária e, principalmente, no comportamento do profissional que pode ser comprometido, caso se tenha baixa maturidade profissional e técnica. Entretanto, o inverso também é verdadeiro, de forma que a maturidade profissional e o AIR podem trazer robustez ao profissional e à ferramenta tecnológica.

Rose (2002), afirma que uma das principais contribuições da TTD é modelagem para confiança, uma vez que a maioria de estudos anteriores (por exemplo, Ashton 1990; Boatsman, Moeckel, & Pei 1997; Whitecotton 1996), apresentaram análises quantitativas da confiança em IA baseados apenas na percepção dos profissionais. Contudo, Arnold e Sutton (1998) argumentam que considerando que a confiança é de difícil mensuração e como a utilização da IA, por exemplo, não implica necessariamente dependência, pois o profissional pode concordar com a orientação sem depender dela, a TTD permite avaliar, isoladamente, quando os indivíduos aceitam e incluem a recomendação do agente inteligente no processo de tomada de decisão. Segundo Arnold e Sutton (1998), embora a confiança seja de difícil mensuração, é possível medi-la em termos de alguns atributos, conforme Tabela 2.

Bonaccio e Dalal (2006) reforçam que muitas (senão a maioria) das decisões importantes nas organizações não são tomadas por uma pessoa agindo sozinha, ou seja, de alguma forma é necessária ajuda e confiança em um segundo elemento. Assim, Hampton (2005) utiliza a TTD para mitigar alguns dos problemas de medição da confiança, ao explicitar que uma vez que a maioria das decisões são tomadas com ajudas, tratar a dependência tecnológica como um construto contínuo que varia de confiança baixa, média à alta, favorece a mensuração do nível de confiança em IA.



Tabela 2  
Mensuração da TTD

<b>Autor (es)</b>	<b>Constructo</b>	<b>Exemplo de Questão</b>
Mălăescu e Sutton (2015)	Intenção de reuso – o usuário demonstra interesse em reutilizar a tecnologia	- É útil? - Pretende reutilizar?
		Continua
		Conclusão
Hampton (2005)	Aceitação – o usuário concorda com a informação da tecnologia com IA incorporando a tecnologia no processo de tomada de decisão;	- Aumentou a eficiência? - Reduziu o tempo?
Jensen et al., (2010).	Credibilidade - Profissionais que usam explicações geradas por um agente inteligente são mais propensos a aderir as decisões e recomendar a tecnologia.	- Oferece desempenho superior? - Recomenda a tecnologia?
Noga e Arnold (2002)	Visão Cognitiva – Profissionais que usam tecnologias com IA tem a percepção de angariarem mais conhecimento	- Reduziu necessidade de análise? - Facilitou a resposta?

Triki e Weisner (2014) ressaltam que quando a TTD foi articulada pela primeira vez, era sugestivo que o apoio da IA na decisão poderia ser usada para fazer com que os profissionais, tomadores de decisão iniciantes, tomassem decisões como mais especialistas do que eram. Mas com a evolução dos estudos (Arnold et al. 2018; Dowling, Leech, & Moroney. 2008; Hampton, 2005; Jensen et al., 2010; Mascha & Smedley 2007; Noga & Arnold, 2002) a sugestão de uso dessa teoria se expandiu, sendo possível sugerir uma medição de confiança, com base na ação, no uso, na aceitação e na experiência do profissional, que instiga analisar se o uso demasiado ou uso sem experiência técnica da IA não causaria dependência e diminuição da capacitação técnica do profissional.

A dependência da tecnologia ou diminuição da capacitação técnica do profissional guarda relação com o próprio processo de aprendizado em um ambiente altamente informatizado. Segundo Göranzon e Josefson (2012), na chamada sociedade da informação, novas formas de pensar, de agir e de comunicar-se são introduzidas como hábitos corriqueiros, afetando as formas de aquisição de conhecimento, assim como de forma corriqueira também são introduzidas as ferramentas que propiciam essa aquisição. Nesse sentido, a IA é apontada pelo autor como uma das principais alternativas para formação e desenvolvimento de profissionais com um perfil que atenda às exigências da sociedade moderna. Portanto, ao contrário da dominância tecnológica, a IA deveria ser utilizada como uma

ferramenta de auxílio no reprocesso de aprendizagem do cenário tecnológico (Recht & Bryan, 2017).

Assim, Trikki e Weisner (2014), descrevem a TTD como um produto da combinação bem-sucedida de habilidades psicológicas, com ciência cognitiva e tecnologia observando que a interação entre os profissionais e as características da tecnologia analisada, no caso a IA, podem ser estudadas a partir de oito proposições da Teoria, descritas na Tabela 3.

**Tabela 3**  
**Proposições da TTD**

<b>Estágio</b>	<b>Situação</b>
1 - Fatores que influenciam a confiança	Quando os usuários têm nível baixo a moderado de experiência, haverá uma relação negativa entre a experiência na atividade e a confiança em IA. Existe uma relação positiva entre a complexidade da atividade e a confiança em IA Quando a experiência e a complexidade da atividade são altas, há uma relação positiva entre a familiaridade com ferramenta de apoio e a confiança na IA. Quando a experiência e a complexidade da atividade são altas, há uma relação positiva entre o ajuste cognitivo e a confiança na IA.
2 - Condições favoráveis à dominância	Quando a especialização do usuário e o auxílio à decisão inteligente são incompatíveis, há uma relação negativa entre o nível de especialização do usuário e o risco de uma tomada de decisão deficiente. Quando o nível de especialização do usuário e o auxílio à decisão inteligente são combinados, existe uma relação positiva entre a dependência do apoio e a melhoria das decisões por meio de IA.
3 - Efeitos a longo prazo	Existe uma relação positiva entre o uso continuado de um auxílio à decisão inteligente e a destreza dos profissionais para o domínio no qual o auxílio é utilizado. Existe uma relação negativa entre o amplo uso de longo prazo de um auxílio à decisão inteligente em um dado domínio de problema e o crescimento do conhecimento e avanço do domínio.

Nota: Adaptado de “*Lessons from the literature on the theory of technology dominance: Possibilities for an extended research framework*”, de Trikki, A., & Weisner, M. M. 2014, *Journal of Emerging Technologies in Accounting*, 11(1), 41-69.

Segundo Trikki e Weisner (2014) as oito proposições testáveis criam uma definição de relação positiva ou negativa do profissional com a IA variando conforme a relevância e a afinidade dos fatores experiência do profissional, complexidade da tarefa e aptidão para tecnologias da informação, bem como avaliando que o uso prolongado sobre uma mesma indagação pode se tornar um processo vicioso e de dependência, onde o domínio tecnológico avança e o conhecimento técnico recua

Para profissionais experientes, a tendência de confiabilidade em IA, dependerá da complexidade da tarefa e da obtenção ou não de ganhos assertivos na tomada da decisão; logo, inexistindo estes fatos, o profissional usará seu conhecimento técnico. Em outras palavras, ele sempre medirá o esforço mental requerido pela atividade (Rose, 2002). Por outro lado, a IA é mais eficaz quando aplicada em auxílio à decisão

de um usuário experiente, uma vez que está compreendida, pela parte humana, a capacidade do auxílio à decisão (Jensen, Lowry, Burgoon, & Nunamaker, (2010).

De forma geral, a TTD trata a recomendação de uma ferramenta ou processo tais como os baseados em IA como a recomendação de um colega eletrônico e propõe então um modelo de mensuração do nível de confiança e aceitação que essa recomendação produz no profissional, sendo esta medida, considerada o nível de aceitação (Arnold & Sutton, 1998).

Assim, no contexto do presente estudo, que tem como ênfase as rotinas tributárias afetadas pela IA, discutem-se nas seções seguintes de maneira mais específica as três principais premissas para o nível de aceitação:

- a) A experiência do profissional tributário;
- b) a especialização (formação) do profissional tributário;
- c) a familiaridade com as tecnologias.

### **2.3 Experiência e especialidade do profissional tributário**

Prado (2015) descreve que a rotina do profissional tributário envolve a junção das áreas contábil e jurídica, uma vez que Direito e Contabilidade são ciências que caminham juntas e se complementam. Corroborando com esse entendimento, Oliveira (2009) escreve que, por conta dessa união, é dever do profissional não só obedecer às normas e princípios da contabilidade, visando à correta apuração da situação econômica, financeira e patrimonial de uma empresa, mas também obedecer e entender as normas de legislação tributária, que não são poucas. Complementa ainda que, para o profissional, o gerenciamento das obrigações não deve ser uma simples obrigação cotidiana, mas sim uma ferramenta estratégica.

Para Mello (2013), diante da complexidade e do volume dos tributos no Brasil, o desempenho das funções de um profissional tributário exige habilidades e conhecimentos que fogem de sua característica habitual, uma vez que o profissional deixa de ser um simples “analista” e passa a exercer um papel de maior relevância na tomada de decisões, tornando-se, logo, um profissional mais estratégico.

Jordão, Silva, Brasil e Vasconcelos (2016) realizaram um estudo sobre a escrituração digital no Brasil e, após analisar as respostas de 130 profissionais que atuam na gestão tributária, concluíram que os dirigentes das empresas e os profissionais tributários envolvidos são bastante carentes de capacitação para as inovações tecnológicas impostas após a implantação do SPED, e sobretudo aquelas

que podem afetar o nível de conformidade da empresa. Segundo os autores, o SPED exige mudanças no aprendizado, nos processos e no comportamento necessários para lidar com as tecnologias da informação.

Anzilago (2014) também ressalta que o profissional tributário deve percorrer uma dinâmica de trabalho que preza mais pelas habilidades interpessoais, comportamentais e analíticas do que somente técnicas. Silva, Silva e Drumond (2015), em sua pesquisa sobre o papel do profissional na implementação do SPED, destaca uma mudança brusca, imposta pelo fisco, nas rotinas operacionais, evidenciando não somente a precisão das tarefas executadas pelos profissionais tributários, mas também a necessidade de que estes trabalhem de forma integrada com os demais colaboradores da empresa. Logo, o SPED introduziu uma necessidade de mudança no padrão de comportamento e pensamento do profissional tributário, em que suas decisões refletem diretamente nas atividades de muitos outros agentes na organização.

Em relação à formação do profissional tributário no Brasil, no entanto, Martins, Schlemper, Schutz e Braun (2018) não conseguiram identificar, na formação universitária dos profissionais, se os alunos serão capazes de atender as demandas tecnológicas, pois ainda que na formação dos profissionais seja comum a oferta de atividades envolvendo a contabilidade digital, temas da ciência de dados não estão explícitos nos currículos oferecidos pelas universidades brasileiras. E essa não é uma responsabilidade exclusiva dos cursos, já que, como apontam Blouch, Ulrich e Michenzi (2010), durante a graduação os alunos tendem a focar apenas nas competências técnicas requeridas para a qualificação no exame de suficiência profissional.

Talvez pela falta de qualificação na formação acadêmica dos profissionais tributários, estudos mostram que as empresas têm preferência por contratar profissionais com experiência, em todos os níveis hierárquicos (Peleias, Guimarães, Silva & Ornelas, 2008; Pires, Ott, & Damacena, 2009; Santos, Sobral, Correa, Antonovz & Santos, 2011; Tamer, Viana, Soares, & Lima, 2013), embora a forte demanda por profissionais que atuam na gestão tributária acabe fazendo com que muitas vezes as empresas contratem profissionais sem experiência, e que, conforme a TTD, podem estar mais sujeitos à dominância da IA.

Assim, diante da diversidade de conhecimentos técnicos e comportamentais demandados pela gestão tributária, somada à complexidade das atividades

rotineiras na área, é premente que a experiência do profissional, a despeito de sua formação acadêmica, influencie ou seja influenciada pela IA. A partir deste entendimento, formulam-se as seguintes hipóteses:

**H1** – Quanto menor a experiência do profissional tributário, maior a dominância da IA.

**H2** - Quanto maior a especialização do profissional tributário, menor a dominância da IA.

No contexto do presente trabalho, a experiência é entendida como vivência profissional, enquanto a especialização é entendida como educação técnica. Assim, a experiência do profissional tributário será aqui representada pelo tempo de vivência do profissional na área. Já a especialização será representada pela formação acadêmica e técnica, sendo que o profissional com menor experiência pode, alternativamente, apresentar maior nível de dedicação a estudos específicos, o que pode ser um facilitador para a mudança do *status quo* na área, uma vez que maior tempo de dedicação aos estudos pode sugerir uma postura mais inovativa.

A primeira métrica avalia o perfil do profissional e sua experiência na área de forma a permitir classificá-lo nesse estudo, ou seja, definir se é um especialista em impostos, um analista iniciante ou se apresenta experiência média. Para tanto, a primeira parte do questionário contemplará a formação do respondente e sua experiência.

## **2.4 Familiaridade com as Novas Tecnologias da Informação e Comunicações**

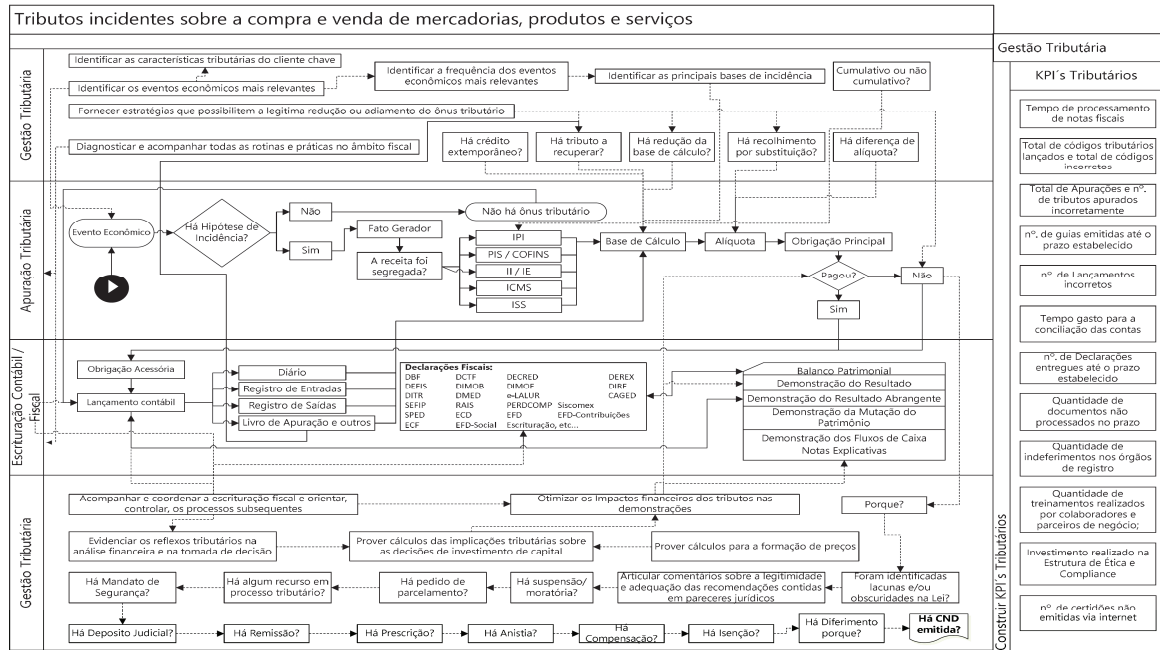
As transformações da economia mundial nas últimas décadas aumentaram a complexidade na apuração e pagamento de impostos, com as empresas operando em diferentes territórios, cada um com um sistema tributário próprio. As novas tecnologias, como a IA, podem levar os profissionais que trabalham na área a uma certa simplificação, e não somente no caso das grandes empresas, já que a globalização e as ferramentas disponíveis atualmente permitem que pequenas e médias empresas operem se beneficiando da tecnologia, diante da tamanha complexidade da área.

Em se tratando de familiaridade com novas tecnologias, a complexidade passa a ser um atributo motivador na apuração e pagamentos de impostos. Esnolde, Galo,

Parisi e Pereira (2009) descrevem que essas rotinas no Brasil são complexas, trazendo muitas vezes desembolsos financeiros desnecessários às empresas, e causando-lhes, ainda, a constante insegurança de estar ou não cumprindo com todas as obrigações exigidas pelo fisco. Essa insegurança ocorre, primeiramente, em função dos aproximadamente 90 tributos cobrados no Brasil, entre impostos, taxas e contribuições. Em segundo lugar, pela quantidade de normas que regem o sistema tributário (são aproximadamente 350.000 normas tributárias, com média de duas normas editadas por hora). Em terceiro lugar, em virtude de haver aproximadamente 90 obrigações acessórias que as empresas devem cumprir para tentar estar em dia com o fisco, compreendendo um conjunto de declarações, formulários, livros, guias, etc. (Instituto Brasileiro de Planejamento e Tributação, [IBPT], 2018). Nazareth (2018), ao descrever o Sistema de Informação dos tributos incidentes sobre vendas no Brasil, retrata graficamente este cenário, conforme demonstrado na Figura 1.

Em uma perspectiva multidisciplinar, as rotinas tributárias extrapolam as barreiras do departamento fiscal, pois perpassam por outros departamentos da empresa, ou seja, diversos departamentos fazem parte das tarefas tributárias, exigindo o tratamento de informações de fontes tão diversas como produção e finanças.

A complexidade do sistema tributário brasileiro traz desconfortos aos contribuintes e já começa a ser denunciada pela exaustiva lista de tributos aplicados no país, os quais precisam ser conhecidos por profissionais e empresários, bem como apurados pelos analistas fiscais. Ainda há as subdivisões das rotinas, como gestão tributária da informação inicial de forma que a empresa não internalize problemas de seus clientes e fornecedores, escrituração fiscal, apuração dos impostos e, por fim, gestão tributária das informações finais, de forma que a garantia do *compliance* seja algo cíclico, ético e transparente.



**Figura 1.** Incidência dos Impostos nas operações de compras e vendas de produtos, mercadorias e serviços.

Fonte: Recuperado de "Controladoria Tributária: Uma Contribuição para a sua Estrutura Conceitual" de Nazareth, L. G. C. (2018), (Tese de Doutorado). Universidade Metodista de Piracicaba.

A escrituração fiscal é uma das obrigações dos profissionais tributários com as autoridades fiscais. Trata-se de uma prestação de contas ao fisco sobre as movimentações, o faturamento, os impostos a serem pagos e outras informações de interesse do governo. Até 2007, essa prestação de contas era predominantemente realizada de maneira manual, com base nos livros e registros físicos que os profissionais tributários produziam. Porém, com o advento da tecnologia, notas fiscais passaram a ser eletrônicas e escriturações entregues digitalmente, pela imposição do Fisco na adoção do SPED. Também é possível notar que o SPED promoveu uma intensa integração de dados, com o crescimento significativo da implantação de sistemas ERP no Brasil, inclusive em pequenas empresas (Rose, 2002).

Borges (2011) argumenta que, além do desconforto com a complexidade dos processos, as tarefas atribuídas ao profissional tributário no Brasil, relacionadas a seguir, exigem todo tipo de suporte, incluindo o institucional e o tecnológico (inclusive da IA):

- Esclarecer questões complexas ou controvertidas na dinâmica dos tributos incidentes nas operações das atividades econômicas das empresas e de todo o grupo;
- diagnosticar e acompanhar todas as rotinas e práticas no âmbito fiscal;
- acompanhar e coordenar a escrituração fiscal, e orientar e controlar os processos subsequentes;

- d) acompanhar as disposições legais e manifestações jurisprudenciais que respaldam as rotinas e as práticas fiscais;
- e) fornecer estratégias que possibilitem a legítima eliminação, redução ou adiamento do ônus tributário;
- f) realizar avaliações de viabilidade fiscal das transações econômicas;
- g) identificar questões tributárias resultantes de lacunas e obscuridades da legislação;
- h) articular comentários sobre a legitimidade e adequação das recomendações contidas em pareceres jurídicos expedidos por advogados e auditores;
- i) elaborar sistemas de acompanhamento e controle interno necessários à obtenção de elevada produtividade no cumprimento das obrigações fiscais;
- j) subsidiar o processo de planejamento tributário;
- k) acompanhar o trabalho dos auditores;
- l) conduzir a sincronização da contabilidade tributária com a gestão e o planejamento tributário.

Outro exemplo da complexidade tributária no Brasil envolve as iniciativas de *ranking* dos contribuintes em termos de conformidade tributária. Por exemplo, o Estado de São Paulo, publicou em 2018 a Lei Complementar nº 1.320, que instituiu o Programa de Estímulo à Conformidade Tributária - "Nos Conformes". A norma, que também está sendo implantada em outros estados e na Receita Federal, busca categorizar os contribuintes pelo risco de não conformidade, atribuindo notas melhores para empresas que estão em melhor conformidade. A classificação dos contribuintes ocorre em termos de adimplência (prazo de atraso, inscrição em dívida ativa, omissão de GIA, atraso de GIA), aderência (percentual de aderência, omissão de Escrituração Fiscal Digital - EFD, EFD incompleta, atraso de EFD) e perfil com fornecedores (o nível de conformidade dos fornecedores afeta o nível de conformidade da empresa).

Embora a Lei 1.320/2018 declare que o objetivo da classificação seja conceder incentivos, que incluem melhorar a reputação e o acesso ao crédito das empresas, procedimentos simplificados de monitoramento e auditoria e opções de autorregulação, além incentivar a criação de cadeias de valor com fornecedores mais competitiva tributariamente, do ponto de vista da gestão tributária ela tem potencial para aumentar custos de conformidade, uma vez que exige maior transparência e alinhamento com o fisco dos interesses dos contribuintes.



Nesse cenário, onde temos os diferentes aspectos da complexidade tributária exposta, observa-se a oportunidade de robotizar diversos processos decisórios, como critérios para o fechamento mensal, regras para preenchimento e envio de obrigações acessórias, padronização de arquivos de documentos, bem como fluxos operacionais para recebimento, emissão e escrituração de notas fiscais, fluxo para pagamento de guias e fluxo de controle de geração e certidões negativas, entre outros exemplos.

Segundo Nazareth (2018), os processos tributários no Brasil compreendem escolher o melhor regime tributário, interpretar a legislação que afeta a empresa, identificar quais são as obrigações que devem ser seguidas e calcular os tributos, entre outras rotinas, muitos dos quais podem ser robotizáveis com auxílio da IA), de forma que um processo eficiente de apuração de impostos contribui para evitar uma série de situações que seriam prejudiciais para a empresa, como impostos pagos em excesso, pagamento de multas e juros, dificuldade no acesso a linhas de crédito, impedimento de participar em licitações públicas e responder a processos judiciais. Além do cumprimento das obrigações tributárias, existe a necessidade de análise gerencial dos números tributários, que envolve o monitoramento de KPIs (*Key Performance Indicator*), utilizados para gerenciar riscos e oportunidades tributárias.

Diante de todas as complexidades citadas, a maior competição das organizações, especialmente as mais complexas e diferenciadas, requer sistemas de controle e rotinas mais sofisticadas para a coordenação e integração organizacional (Williamson, 1985). As características estruturais das organizações, tais como o tamanho e as rotinas, determinam as mudanças e relevância da tecnologia em uma área profissional (Luft & Shields, 2003).

Assim, os processos da gestão tributária devem estar adequados às regras e leis para que nenhuma informação errônea seja entregue ao Fisco, seja no âmbito municipal, estadual ou federal. Logo, automatizar o processo é indispensável, mesmo que ofereça, no início, custo adicional para a organização (Kokina & Davenport, 2017). No Brasil, a adoção mais intensa da tecnologia na área tributária teve início em 1991, com a publicação da Lei 8.219, que estabeleceu em seu Art. 11 que as pessoas jurídicas que utilizassem sistemas de processamento eletrônico de dados para registrar negócios e atividades econômicas ou financeiras, escriturar livros ou elaborar documentos de natureza contábil ou fiscal, ficariam obrigadas a manter os respectivos arquivos digitais à disposição da Secretaria da Receita Federal, Outro marco foi a

adoção, em 1995, do Convênio 57, alcançando as informações de natureza tributária no âmbito dos estados (ICMS – Imposto sobre circulação de mercadorias e serviços).

Desde então, observa-se que os processos tributários no Brasil passaram a migrar para plataformas de informática, ainda que sem muita “racionalização” ou “inteligência”. Como exemplo disso, observa-se a forma de envio das informações do Imposto de Renda da Pessoa Física, que no Brasil é 100% entregue via Internet, enquanto em muitos países desenvolvidos a informação ainda é entregue, principalmente, por meio de formulários impressos, pois não existem softwares gratuitos oferecidos pelo governo, como no Brasil.

Outro exemplo de tecnologia tributária no Brasil é o SPED. O Sistema pode ser definido como um instrumento que unifica as atividades de recepção, validação, armazenamento e autenticação de livros e documentos integrantes da escrituração comercial e fiscal das empresas mediante fluxo único e computadorizado de informações. A princípio, ele proporcionaria benefícios para os contribuintes, como, por exemplo a simplificação das obrigações acessórias (Dinis, 2009). Contudo, Geron, Finatelli, Faria e Carmo Romeiro (2011) concluíram que, considerando que um dos maiores benefícios do SPED para o profissional tributário seria a redução das obrigações acessórias, não foi o que se constatou, sendo que 82% dos profissionais pesquisados não perceberam qualquer redução em suas obrigações acessórias, e 8% deixaram de entregar apenas uma, sendo que a mais comum corresponde à não impressão dos livros contábeis. Como conclusão, os autores entendem que o SPED adicionou desconfortos ao ambiente já existente.

Já os sistemas utilizados para apoio e geração das informações do SPED são os ERP (*Enterprise Resource Planning*), que coletam e processam dados tributários, sendo, ainda, necessário a intermediação do usuário profissional (Leão, Isatto, Formoso, & Torres, 2016). Cordeiro e Klann (2015), observa que os ERPs no Brasil sofreram uma drástica mudança a partir da implantação do SPED, exigindo uma integração maior de validações tributárias nos processos dentro e fora da área tributária, para que as informações pudessem ser entregues ao Fisco em conformidade, considerando complexidade e volume de informações periódicas.

Outra tecnologia usada na gestão tributária, o Big Data, contempla diferentes ferramentas de bancos de dados. Segundo Wu, Ou, Lin, Chang & Yen (2012), mais e mais empresas estão usando ferramentas ao analisar as vendas e outros dados transacionais relacionados para detectar inconformidades tributárias, de forma que

várias empresas de software, como a International Business Machines Corporation - IBM, oferecem sistemas com orientação para detecção de falhas, com base na integração da IA com *Data Warehouses*, que são utilizados para coletar dados de diferentes fontes que podem ser organizados em armazenamento de dados semântico e integrado (Nycz & Smok, 2003), suportando a geração de informações estruturadas e específicas, como as tributárias.

Frawley et al. (1992), descrevem outro processo aplicado à gestão tributária, o *Data Mining*, um processo para descobrir o incerto, desconhecido e oculto das informações de um banco de dados. Grupe e Owrang (1995) definem *data mining* como um método de relacionar dados existentes que ainda não foram descobertos por especialistas. Linoff e Berry (2011) consideram *data mining* como uma análise que faz uso de ferramentas automáticas ou semiautomáticas para descobrir relacionamentos significativos ou regras a partir de uma enorme quantidade de dados. Contudo, três características importantes distinguem a técnica de *data mining* de outros métodos estatísticos (Hand, 1998, 1999). Primeiro, é capaz de categorizar grandes quantidades de dados para análise secundária. Segundo, é capaz de abstrair informações de dados do aplicativo operacional de sistemas, em vez de se basearem em experiências anteriores. Finalmente, pode descobrir padrões e relacionamentos em dados, modelos e técnicas que deram base ao *Data Warehouse*, que nada mais é do que a área de descoberta de conhecimento útil em grande base de dados (*Big data*), apontando padrões e tendências impossíveis de se perceber sem o emprego do *data mining*.

Finalmente, especificamente sobre a IA, estudo realizado pela International Data Corporation [IDC] (2018) com funcionários de agências arrecadoras, pessoas com atividades empresariais, empresários e executivos de grandes empresas, bem como organizações ligadas a processos de arrecadação de impostos, mostra que 74% dos contribuintes na América Latina acreditam que o sistema fiscal necessita não apenas de uma modernização, mas de uma reengenharia total do processo por meio da IA. A mesma visão é compartilhada por 50% das agências arrecadoras e 57% das agências reguladoras. O estudo relata exemplos como o município de Caruaru (PE), que utilizou uma tecnologia de IA da Microsoft para o planejamento de ações voltadas a aumentar a receita da cidade, e a Secretaria da Fazenda Estadual do Pará, que utiliza a mesma plataforma de IA para monitorar a dívida tributária. Em ambos os

casos, o estudo remete à necessidade corporativa de alinhamento entre tecnologias e as demandas implantadas pela administração pública.

Assim, a IA e todos os seus mecanismos tecnológicos provocam uma disruptura social e tecnológica. Como observam Sutton et al. (2016), em seu estudo *“The reports of my death are greatly exaggerated -Artificial intelligence research in accounting”*, a IA vem sendo adotada intensamente na área contábil e tributária, embora muitos processos ainda não tenham incorporado tais ferramentas. Assim, considerando que a familiaridade com a tecnologia na área tributária pode influenciar e ser influenciada pela IA, surge a terceira hipótese deste estudo:

**H3.** Quanto maior a familiaridade do profissional com tecnologias aplicadas à gestão tributária, maior é a dominância da IA.

Essa familiaridade do profissional é medida pela quantidade de ferramentas tecnológicas que este profissional inseriu ou usa em suas atividades rotineiras, aderindo-as, bem como pela habilidade de ver possibilidades de automatizações no cenário tributário de uma empresa.

Com base nestes achados temos, então, as três hipóteses para pesquisa, resumidas na Tabela 4.

Tabela 4

#### Definição das Hipóteses e Variáveis

Hipótese	Variável Independente	Métrica	Relação com a TTD (Variável Dependente)
H1	EXP – Experiência	Anos na área	Maior EXP, menor TTD
H2	ESP – Especialização	Nível de formação	Menor ESP, maior TTD
H3	FAM – Familiaridade	Uso de tecnologia no dia a dia	Maior FAM, maior TTD

Segundo Hampton (2005), Jensen et. al (2010), Mălăescu e Sutton (2015) e Noga e Arnold (2002), estudos anteriores chegaram a testar o nível de familiaridade, experiência e especialização dos profissionais apoiadas por uma ferramenta com tecnologia, por exemplo, a IA, no entanto, as percepções dos usuários sobre tais itens tiveram a possibilidade de serem medidos a partir do estudo de Arnold e Sutton (1998), em grande parte devido à dificuldade de se estabelecer um instrumento e mensuração

destas variáveis. Logo, as escalas apresentadas serão utilizadas para medir as três variáveis independentes deste estudo (experiência, especialização do usuário e familiaridade com IA) e a variável dependente (dependência da IA), as quais foram extraídas da literatura da TTD.

Cabe destacar que, embora estudos anteriores como os de Hampton (2005); Jensen et al. (2010); Mălăescu & Sutton (2015) e Noga e Arnold (2002), não tenham sido realizados no ambiente corporativo, como será este estudo, mas em universidades, com alunos, compreende-se que as métricas são igualmente operacionalizáveis.

### **3 Metodologia**

Esta seção contempla a fase de definição de campo, gerando a escolha do espaço da pesquisa, do grupo, do tipo da pesquisa, classificando-a em pesquisa quantitativa e/ou qualitativa e estabelecimento dos critérios de amostragem, como também a definição de instrumentos e procedimentos para análise dos dados (Martins & Theóphilo, 2009).

O objetivo da presente pesquisa a classifica como uma pesquisa descritiva pois, segundo as orientações de Cervo e Bervian (2002), a pesquisa descritiva se caracteriza na observação, registro, análise e estabelecimento de correlação de fatos ou fenômenos sem manipulá-los. Sendo assim, a pesquisa irá explorar, dentro de uma amostra de empresas, as competências dos profissionais mediante o uso contínuo da inteligência artificial.

Quanto à a natureza, será uma pesquisa quantitativa, já que, conforme define Collis e Hussey (2005), é uma classificação do método científico que utiliza diferentes técnicas estatísticas para quantificar opiniões e informações para um determinado estudo. Ela é realizada para compreender e enfatizar o raciocínio lógico e todas as informações que se possam mensurar as experiências humanas, pois envolve análise, exame e reflexão sobre percepções para obter um entendimento das atividades sociais e humanas, com a intenção de compreender o comportamento humano a partir da estrutura de referência do participante.

A abordagem de estudo é a de uma pesquisa causal, baseada em quase-experimento. Segundo Holland (1986), a inferência causal relaciona-se com a expectativa de que a mudança em uma variável produza mudança em outra variável. Assim, o foco não é buscar causas de efeitos, mas sim encontrar os efeitos de causas. No presente estudo, o efeito é a confiança em IA, que varia dependendo da experiência, da especialização e da familiaridade com tecnologias para a área (causas).

#### **3.1 Inferência causal**

Segundo Holland (1986), a apresentação das premissas da inferência causal torna visíveis as passagens lógicas assumidas na construção do conceito de risco, permitindo entendê-lo "por dentro". Esta vertente tenta demonstrar que a estatística é capaz de inferir causalidade no lugar de simplesmente evidenciar associações estatísticas, estimando em um modelo o que é definido como o efeito de uma causa.

Assim, o raciocínio causal pressupõe que uma ação causa outra, ou seja, A causa B. Isso implica comparar a exposição com a não-exposição à causa, ou, na linguagem da experimentação, o tratamento com o não-tratamento ou controle, além de ser fundamental que cada unidade seja potencialmente exposta a qualquer uma das causas. Nesse sentido, é fundamental o modo como os indivíduos são alocados nos grupos de comparação. Além disso, esta concepção exclui os atributos pessoais como passíveis de serem causas.

Vale ressaltar que inferir causalidade diz respeito a efeitos de causas em indivíduos (unidades) específicos, bem como os efeitos de causas que ocorrem na singularidade. Isto implica o chamado "problema fundamental da inferência causal", não sendo possível observar simultaneamente o valor do tratamento e do não-tratamento ("A" e "não A") na mesma unidade. Assim, como solução no caso em que se trabalha a individualidade, faz-se uso da estatística substituindo a impossibilidade de observar o efeito causal em um determinado cenário pela possibilidade de estimar o "efeito causal médio" em uma população de indivíduos. Essa estratégia implica a necessidade de trabalhar com amostras da população, sendo necessário, portanto, garantir que todos os indivíduos da amostra sejam passíveis de serem expostos igualmente ao tratamento e ao não-tratamento, por meio da alocação dos indivíduos nos grupos de comparação de maneira aleatória.

Quanto ao método quase-experimental, será descrito, com exemplos, na seção seguinte.

### **3.2 Quase experimento**

O design experimental do presente trabalho é baseado no estudo de Hampton (2005), Jensen et al (2010); Mălăescu & Sutton (2015) e Noga e Arnold (2002), intrinsecamente relacionado à TTD.

Noga e Arnold (2002), considerando o aumento da complexidade tributária e o quanto isso pode afetar a conformidade do contribuinte, desenvolveram um estudo com 79 estudantes universitários, com diferentes níveis de experiência, com o objetivo de examinar se os profissionais tributários que preparam manualmente uma declaração de imposto de renda tomam as mesmas decisões que os profissionais tributários que fazem uso de uma tecnologia. Assim, os estudantes preencheram duas declarações de imposto de renda (uma mais simples e outra mais complexa) e foram aleatoriamente separados em dois grupos (controle e análise), sendo que o primeiro grupo utilizou a IA para desenvolver a tarefa e o segundo grupo não, concluindo-se

que o uso de uma tecnologia ajudará usuários iniciantes e experientes a tomar melhores decisões, resultando em um maior nível de conformidade fiscal, bem como que os menos experientes não poderão usar o suporte baseado em IA tão eficazmente quanto os profissionais mais experientes, ou seja, à medida que as declarações de impostos se tornam mais e mais complexas, os contribuintes podem ser bem aconselhados a procurar a ajuda de um especialista, em vez de depender de uma tecnologia para preparar a própria declaração de imposto de renda.

Hampton (2005), tendo como base a constatação de que os usuários iniciantes não têm experiência para interagir corretamente com a tecnologia na área tributária, enquanto os usuários experientes frequentemente se recusam a usar ou confiar nas recomendações do recurso com IA, realizou o estudo considerando testar, empiricamente, os quatro fatores da TTD: a experiência na tarefa, a complexidade da tarefa, a familiaridade com tecnologia e o ajuste cognitivo. Assim, 76 estudantes fizeram parte desta pesquisa, que ocorreu em três fases, durante duas semanas, onde os participantes foram separados em grupos, pelo nível de familiaridade com a tecnologia e experiência com a tarefa.

Na primeira fase, que foi conduzida em um único cenário, todos os participantes completaram um teste de controle para estabelecer seu nível inicial de conhecimento sobre a tarefa (auditoria). Na segunda fase, os participantes completaram três tarefas de avaliação de adequação de controle interno. E na terceira fase, o procedimento da primeira fase foi repetido, atentando-se ao fato que não foi oferecido treinamento sobre a tecnologia e os casos foram trocados entre os participantes. Concluiu-se que os profissionais mais experientes demonstram maior confiança no uso da tecnologia ao avaliar tarefas complexas versus simples, de forma que os resultados da complexidade da tarefa indicam que estes profissionais mostrarão maior confiança no uso da IA onde a tarefa seja complexa o suficiente para que o esforço cognitivo necessário para resolver o problema sem IA seja maior do que o esforço cognitivo usando uma tecnologia. Em relação aos profissionais menos experientes, o estudo mostra que por não terem a experiência necessária para avaliar as decisões de uma tecnologia com IA, eles, demonstram um grau maior de confiança no uso da tecnologia, possibilitando que venham a ter mais experiência no futuro, consideradas as informações relevantes que a tecnologia pode fornecer e o desenvolvimento de análise crítica por parte deste novo profissional.



Jensen et al. (2010) desenvolveram um estudo sobre avaliação de credibilidade de notícias por meio de ferramentas com tecnologias, visto que tais ferramentas têm sido muito importantes nas tomadas de decisões, mas ainda pouco exploradas em pesquisas. Assim, aplicaram o estudo a um total de 51 estudantes, considerando profissionais experientes os que já possuíam formação na área de comunicação, aproximadamente metade do grupo, enquanto a outra metade, sem formação na área, seriam os profissionais menos experientes. Os testes foram conduzidos com os profissionais, que deveriam avaliar a veracidade de determinadas notícias, sendo que todos contaram com o apoio de uma ferramenta tecnológica para realizar esta avaliação (sendo que parte dos profissionais experientes e inexperientes receberam treinamento prévio sobre a ferramenta), de forma que foi criado por eles um sistema de suporte à decisão (ferramenta tecnológica) que aumentava as capacidades dos usuários, fossem iniciantes ou profissionais.

Usando hipóteses baseadas na TTD, testaram o suporte à decisão em entrevistas, concluindo que tanto os profissionais como os novatos melhoraram sua precisão de avaliação usando a ferramenta tecnológica, ou seja, em consonância com a TTD, os novatos confiavam mais no suporte à decisão do que os profissionais; entretanto, contrariamente à TTD, não houve diferença significativa na maneira como os novatos e os profissionais interagiram com o sistema, e o suporte à decisão não foi mais benéfico para os profissionais mais experientes.

Mălăescu e Sutton (2015) desenvolveram um estudo com 101 estudantes, classificando alunos da pós-graduação como mais experientes e alunos da graduação como menos experientes. O experimento foi conduzido de modo semelhante ao trabalho de Noga e Arnold (2002), ou seja, tendo como objeto o preenchimento de declarações de imposto de renda. O experimento consistiu em três partes. Primeiro, os participantes foram convidados a preencher um questionário para avaliar sua experiência com a preparação e apresentação de declarações fiscais, bem como sua experiência com uso de software fiscal. Em segundo lugar, os participantes preencheram duas declarações, uma mais simples e outra mais complexa. Finalmente, os participantes foram convidados a avaliar suas percepções do software utilizado, em termos de carga cognitiva, utilidade percebida e intenções de reutilização (comportamental), concluindo-se que os profissionais menos experientes perceberam que uma ferramenta mais restritiva de apoio à decisão com IA era mais útil e, portanto, teriam uma maior intenção de reutilizar o suporte decisório com uma tarefa

semelhante no futuro, de forma que este resultado consiste com a TTD de que software restritivo fornece maior capacidade de tarefa para novatos que, portanto, aplicam sua menor carga cognitiva ao completar uma tarefa complexa. Por outro lado, os profissionais mais experientes sentem-se frustrados com este tipo de tecnologia, visto que percebem que o suporte à decisão restritiva requer mais esforço para concluir uma tarefa complexa e, assim, preferem tecnologias com IA menos restritiva, que permitam escolher a ordem na qual a informação é inserida, conferirem uma sensação maior de controle da tomada de decisão, ou seja, estes profissionais não querem que a carga cognitiva seja reduzida em suas ações.

Com abordagem semelhante à dos trabalhos citados, o presente estudo propõe-se a desenvolver um quase-experimento, que é intermediário entre um experimento com distribuição aleatória e um pré-experimento, frequentemente ininterpretável (Campbell, 1979). Como a distribuição aleatória é inviável devido à caracterização dos respondentes em termos de experiência tributária e familiaridade com a IA, segundo Martins e Theóphilo (2009), um quase-experimento, então, é a melhor escolha.

### **3.3 Campo de estudo - busca legal**

O estudo analisa um grupo de profissionais usuários de uma aplicação tributária de IA, denominada Busca.Legal, e um outro grupo ainda não usuário. A Busca.Legal é uma plataforma que busca, por meio da inteligência artificial, facilitar o processo de classificação de operações tributárias no Brasil, denominada Nomenclatura Comum do Mercosul (NCM). Nesta plataforma há um *chatbot* para gestão tributária com a plataforma IBM Watson, que traz de imediato a resposta provável ao questionamento.

Esta ferramenta fornece em sua plataforma online os parâmetros dos tributos estaduais e uma parte dos tributos federais (ICMS, ICMS-ST, IPI, PIS e COFINS), como informações sobre o CEST, CST, alíquota, MVA, pauta e benefícios fiscais, informando ainda a base legal da classificação e tributação, bem como combina regras tributárias, conforme situação e produto.

As classificações e indicações de tributação da Busca.Legal abrangem as operações de vendas internas das 27 unidades federativas, sendo que para o PIS e a COFINS são consideradas as alíquotas aplicáveis ao regime não cumulativo e os

tratamentos diferenciados, como benefícios fiscais ou incidência monofásica, que são aplicáveis a ambos regimes.

A plataforma também pode ser usada por empresas que adotam o regime tributário Simples Nacional e queiram saber quais produtos estão na incidência monofásica, na substituição tributária ou mesmo que possuam benefícios fiscais, para que possam fazer as devidas segregações de receitas para redução do montante a recolher no regime unificado.

A robustez da ferramenta é originada de um banco de dados de tributação com mais de 2 milhões de produtos, 4 milhões de regras tributárias e 18 milhões de situações específicas, conforme informações da Systax, e ainda permite uma escolha de segmento de mercado, podendo ser indústria, atacado ou varejo, trazendo diversidade ao usuário e uma maior afinidade com o *compliance*.

Ainda segundo a empresa, uma análise que exige em média uma hora manualmente é realizada em segundos pela ferramenta. Com tal feito, concorrendo com mais de 1,3 mil parceiros de sete regiões do mundo, a plataforma da Busca.Legal venceu em 2017 o desafio *Watson Build*, promovido pela IBM, sendo este o primeiro desafio cognitivo da IBM projetado exclusivamente para parceiros comerciais.,

### **3.4 Procedimentos metodológicos**

A pesquisa será conduzida em formato de questionários eletrônicos, contando também com o apoio dos desenvolvedores da plataforma para monitorar a realização do experimento, de forma a aproximar o entrevistado do entrevistador.

Os procedimentos, relatados a seguir, buscam explicar o delineamento do quase experimento, incluindo as seleções de população e definição da amostra. Em seguida, discute-se os itens que poderão ameaçar a validade interna e externa da pesquisa, uma vez que a validade é a principal preocupação em relação às variáveis não controláveis, que podem influenciar o experimento e, conseqüentemente, a forma de se interpretar os dados (Campbell, 1957).

#### **3.4.1 Delineamento do quase experimento**


Segundo Martins e Theóphilo (2009), um quase-experimento é elaborado por estudos que adaptam propósito de pesquisa onde se tem a necessidade de avaliar a correlação entre variáveis no ambiente conceitual, sendo necessário definir os enigmas, listados na Tabela 5:

Tabela 5  
Definição de Enigmas

Itens	Definição
Grupo de Tratamento	Profissionais que utilizam o Busca.Legal
Grupo de Controle	Profissionais que não utilizam o Busca.Legal
Distribuição Aleatória	Separação dos profissionais em dois grupos
Pré-teste	Foi aplicado após montagem do cenário e estudo piloto
Teste	Causa e efeito do uso da IA
Variável Dependente	TTD – Teoria da Dominância Tecnológica
Variáveis Independentes	Experiência, especialização e familiaridade com TI
Métrica Experiência	Tempo de trabalho na área
Métrica Especialização	Cumulatividade de graduação e cursos profissionalizantes
Métrica Familiaridade	Quantidade de tecnologia usada no dia a dia

*Nota:* Fonte: Adaptado de “Metodologia da investigação científica”, de Martins & Theóphilo (2009).

Assim, no delineamento desse quase experimento, na fase de pré-teste e teste, junto aos profissionais investigados, dois grupos serão separados entre profissionais clientes (C) e não clientes (NC), conforme Figura 2:



**Figura 2.** Delineamento de um quase experimento.

*Nota:* Fonte: Adaptado de “Delineamentos experimentais e quase experimentais de pesquisa”, de Campbell, D. T. 1979.

O uso de dois grupos auxilia na confiabilidade dos resultados obtidos, pois mediremos o efeito do uso da IA comparando a causalidade entre os dois. Em um delineamento que tenha somente um grupo, as explicações dos efeitos e causas evidenciados nos testes teriam diversas rivalidades como interpretação, mesmo sendo estas hipóteses plausíveis (Campbell, 1979)

Assim, neste quase-experimento, o grupo de profissionais não-clientes, aqui representando o grupo controle, reforçará o efeito positivo ou negativo do tratamento aplicado, aqui denominado Inteligência Artificial, no grupo experimental, composto pelos profissionais clientes do Busca.Legal.

Vale ressaltar que o efeito, positivo ou negativo, revelado pela análise do tratamento aplicado responderá o questionamento desta pesquisa, evidenciando o efeito causal da IA na competência do profissional tributário.

### **3.4.2 População e amostra**

A identificação da população e seleção da amostra são itens relevantes na condução de um quase-experimento científico, de forma que Gall, Borg e Gall (2007) reforçam que o primeiro passo na definição de uma amostragem é fazer o “corte” da população alvo.

Essa população alvo é representada por todo o universo em que os resultados da pesquisa poderão ser generalizados – nesta pesquisa, os profissionais tributários brasileiros. Apenas para efeito de representação amostral, estima-se que existam 518 mil contadores atualmente no Brasil, conforme censo do Conselho Federal de Contabilidade (CFC) (2019), e 1,2 milhão de advogados, conforme censo da Ordem dos Advogados do Brasil (OAB) (2019). São esses os profissionais geralmente responsáveis pelas rotinas tributárias nas empresas.

Uma vez feita a delimitação da população, o passo seguinte, segundo Martins e Theóphilo (2009), é a determinação das amostras, de forma que seja possível saber a quantidade de envolvidos no quase-experimento. Nesta pesquisa, a população acessível foi representada por uma determinação de amostra não aleatória, composta por profissionais tributários que atuam nas empresas, clientes e potenciais clientes da Busca.Legal, e estudantes de cursos de pós-graduação em Gestão Tributária de diferentes instituições de ensino.

### **3.5 Condução do experimento**

Para condução do experimento, primeiramente foi realizado o envio do questionário eletrônico para a base de cadastro da Systax (usuários que já tinham contato com a tecnologia de IA). O questionário também foi aplicado em sala de aula para alunos de Pós-Graduação em Gestão Tributária de diferentes IES do Estado de São Paulo (na sua maioria, usuários sem contato anterior com a tecnologia utilizada no experimento).

Quanto ao envio dos questionários pela empresa, ela disponibilizou, sob termos de confidencialidade para pesquisa, a base de cadastro e de acesso ao sistema, para permitir identificar, dentro do teste experimental, aqueles que estariam utilizando pela

primeira vez a ferramenta e aqueles que já estavam habituados ao uso do aplicativo. O questionário continha uma questão para reforçar tal aspecto.

Foi durante a realização dos testes pilotos que se estabeleceu a necessidade e oportunidade de realizar o experimento também *in loco*, nesse caso apresentando a ferramenta e submetendo o questionário para grupos de profissionais da área tributária estudantes de cursos de pós-graduação na área.

Deste modo, o experimento foi conduzido de duas formas distintas:

a) para usuários habituais do Busca.Legal, por meio de envio do questionário eletrônico por e-mail ou apresentação da pesquisa em sala de aula (grupo de tratamento) e;

b) para usuários sem contato anterior com o Busca.Legal, sendo efetuada demonstração da ferramenta e posterior apresentação do questionário eletrônico. (grupo de controle)

### **3.5.1 Pré-teste (O<sub>1</sub>)**

Após a sua preparação, o questionário foi submetido a 6 profissionais tributários, com o objetivo de observar as respostas e colher sugestões de melhorias.

Dentre os respondentes estavam estagiários, analistas da área fiscal e um professor de contabilidade tributária, que receberam o *link* do questionário via e-mail e foram orientados pessoalmente sobre como acessar a ferramenta Busca.Legal.

Nesta fase, a principal recomendação foi o cuidado de dar uma orientação completa do uso da ferramenta, desde o acesso até a navegação, para os profissionais que ainda não tinham utilizado a ferramenta.

### **3.5.2 Acesso ao software Busca.Legal**

Os profissionais que receberam o questionário tiveram ciência de que a ferramenta estava 100% hospedada em um ambiente web e que poderia ser acessada de qualquer lugar e horário, sendo necessário somente acesso ao uso de internet. Os profissionais que receberam o e-mail pelo *mailing* do Busca.Legal foram informados que além do atendimento comercial habitual da empresa, também poderiam contatar os pesquisadores para esclarecimento de dúvidas adicionais.

Quanto aos profissionais estudantes de cursos de pós-graduação em gestão tributária que foram submetidos ao experimento presencialmente, a instrução foi semelhante, com a diferença de que as dúvidas poderiam ser respondidas

pessoalmente com o pesquisador. Contudo, considerando a facilidade de acesso e objetividade na tarefa proposta pelo experimento, não foram observados questionamentos específicos dos profissionais que participaram do experimento presencialmente, em relação aos profissionais que apenas responderam o e-mail.

### **3.5.3 Instrumento de coleta de dados (O<sub>2</sub>)**

O instrumento de coleta de dados constante do Apêndice 2 foi elaborado com base na revisão da literatura e preparado utilizando o recurso *form* do Office 365, que permite a coleta de diversos tipos de dados de forma online e simultânea, inclusive gera gráficos, atualizações em tempo real, bem como monitora o tempo de utilização da pesquisa – neste caso, em média 14 minutos por respondente.

O link foi disponibilizado num formato reduzido, extraído do site bit.ly, e também com um QR Code gerado no próprio *form*.

O instrumento contemplou as perguntas necessárias para avaliar as variáveis dependentes, independentes e de controle, conforme explicado a seguir.

#### **3.5.3.1 Variáveis independentes**

##### **I - Experiência**

Arnold et al. (2004) considerou profissionais experientes aqueles que apresentam mais tempo (em anos) no desenvolvimento da atividade alvo da TTD. Para distinguir profissionais mais ou menos experientes, obteve-se a média de anos de experiência entre os respondentes e estabeleceu-se que os menos experientes seriam aqueles que apresentassem resultado abaixo da média.

Assim, no presente estudo, para mensurar a Experiência, perguntou-se aos profissionais seu:

- a) Tempo de atuação na área tributária;
- b) tempo de atuação no cargo atual;
- c) tempo de atuação com tributos indiretos; e
- d) tempo de atuação com análise da tributação sobre produtos.

A abordagem de múltiplas perguntas se fez necessária pois a atuação apenas na área tributária não implica, necessariamente, experiência com o objeto do presente trabalho (inteligência artificial aplicada a processos relacionados com tributos

indiretos). Assim, para melhor tratamento das respostas, os dados foram solicitados considerando uma escala de 6 pontos:

- a) Menos de 1 ano
- b) Entre 1 e 2 anos
- c) Entre 3 e 4 anos
- d) Entre 5 e 6 anos
- e) Entre 7 e 8 anos
- f) 9 ou mais

Para o menor tempo de experiência atribuiu-se 1 ponto e para o maior tempo de experiência, 6 pontos, atribuindo-se uma média entre as quatro experiências observadas. Com base nessa metodologia, no geral considerando os dois grupos, a experiência destes profissionais respondentes atingiu uma média aproximada de 4 pontos (entre 5 e 6 anos), conforme detalhamento realizado no Capítulo 4.

## **II - Especialização**

Embora Malaescu e Sutton (2015) e Noga (2002) tenham definido experiência em termos de formação (graduados para menor experiência e pós-graduados para maior experiência), para a definição do presente estudo adotou-se a abordagem de Trikki e Weisner (2014), que associou a formação do profissional ao seu grau de especialização.

No presente estudo, os respondentes foram consultados em termos de nível de formação (Graduação, Especialização, Mestrado e Doutorado) e a área de formação (Contábeis, Direito, Administração ou Tecnologia). Foram considerados ‘com maior especialização’ os profissionais que responderam ter nível mínimo de especialização (ou seja, assinalaram especialização, mestrado ou doutorado), nas áreas de contabilidade ou direito; logo, foram considerados profissionais “com menor especialização” àqueles que assinalaram apenas graduação ou, se assinalaram outras formações, não indicaram formação de pós-graduação nas áreas correlatas à gestão tributária (contabilidade e direito).

Se o profissional foi identificado como “com maior especialização”, foi considerada a *dummy* 1 para Especialização. Partindo deste racional, no presente estudo, dos 144 respondentes, 59 profissionais se enquadraram “com maior especialização”, representando 41% da nossa amostra total.



### III - Familiaridade

Conforme definido por Arnold e Sutton (1998), a familiaridade refere-se ao nível de conforto e convívio que um usuário possui com uma tecnologia e resulta de experiências ou treinamentos anteriores com a tecnologia ou um suporte similar. Com base no estudo de Hampton (2005), a mensuração da familiaridade dos profissionais com a IA desenvolvida para este estudo utilizou cinco perguntas, que os respondentes teriam que assinalar com “sim” ou “não”:

- a) Os recursos tecnológicos que utilizo no meu dia a dia são úteis.
- b) Me sinto confortável com o uso das modernas tecnologias.
- c) Me sinto confortável com o uso das decisões baseadas em inteligência artificial.
- d) Pretendo utilizar intensamente a tomada de decisão baseada em inteligência artificial no futuro.
- e) Recomendo o uso de tecnologias e inteligência artificial na área tributária.

Para cada resposta “sim” apresentada pelo respondente, atribuiu-se um ponto à métrica, considerando assim uma escala de 0 (menor familiaridade) a 5 (maior familiaridade) para a variável.

Considerando a metodologia acima observamos que os profissionais respondentes, em sua maioria, indicaram estar mais familiarizados com uso da tecnologia em seu dia a dia, sendo que 70% dos respondentes indicaram a nota 5. Contudo, as variações da métrica levaram a análises complementares conforme demonstrado no Capítulo 4.

#### 3.5.3.2 Variável dependente

Na Seção 2.2. do presente estudo, destinada a apresentar os principais conceitos da TTD, a Tabela 2 resume os principais constructos da teoria e exemplos de questões utilizadas em estudos anteriores para mensurar o nível de Dominância Tecnológica. As questões, adaptadas para o contexto da pesquisa, estão listadas a seguir:

- a) O Busca.Legal reduziu o tempo da tarefa.
- b) O Busca.Legal aumentou a eficiência na resposta.

- c) O Busca.Legal tornou as respostas mais fáceis.
- d) O Busca.Legal mostrou-se útil na minha rotina diária.
- e) Pretendo usar o Busca.Legal nas próximas demandas.
- f) O desempenho alcançado pelo Busca.Legal foi superior ao meu desempenho técnico e manual.
- g) O Busca.Legal reduziu a necessidade de análises técnicas e estratégicas.
- h) Recomendo a Inteligência Artificial do Busca.Legal para rotinas de classificação tributária dos produtos ou mercadorias.

Para cada resposta “sim” apresentada pelo respondente, atribuiu-se um ponto à métrica, considerando assim uma escala de 0 (menor dominância) a 8 (maior dominância) para a variável. Como resultado geral, 74% das respostas se encontraram na faixa de 7 a 8 pontos, indicando maior dominância em relação à IA na área tributária. Ainda assim, a análise estatística revelou *insights* importantes para o estudo.

### 3.5.3.3 Variáveis de controle e explicativas

Para realizar análises robustas, um conjunto de variáveis de controle e explicativas (manipulação) foram utilizadas no estudo para evitar possíveis confusões nos resultados.

A primeira variável, necessária para identificação do grupo de análise (tratamento ou controle), perguntou-se era o primeiro acesso à ferramenta do Busca.Legal, onde os respondentes deveriam assinalar as opções “sim” ou “não”. Consideramos as respostas de primeiro acesso (respostas sim), como profissionais não usuários, alocando-os no grupo de controle, perfazendo um total de 68 respondentes e os demais, já usuários da ferramenta com IA (respostas não), no grupo de tratamento, que somaram a quantidade de 76 profissionais respondentes. Foi feita análise estatística de dados desta variável, estando representada na Figura 5 do capítulo 4.

O segundo grupo de variáveis se referem à dados demográficos: sexo, idade, região e cargo ocupado. A base para seleção dessas variáveis foram os estudos de Axelsen (2012), Hampton (2005) e Jensen et al. (2010).

Para idade, o instrumento de coleta solicitou que os respondentes assinalassem as seguintes faixas: a) Entre 18 e 25; b) Entre 26 e 35; c) Entre 36 e 45;

d) Entre 46 e 55 e Acima de 55. O teste de significância desta variável está representado na Figura 14 e pode ser localizado na Tabela 6 pelo código “IDAD”.

Para região, considerando a expectativa do estudo alcançar profissionais de outras regiões do país além da região sudeste, que concentra grande parte da economia do país, foi incluída uma questão para identificar a localização do respondente.

Para o cargo ocupado, foi utilizada a classificação de Rocha e Silva (2019): Assistente, Auxiliar, Analista, Especialista, Coordenador, Supervisor e Gerente. A variável foi utilizada por Arnold et al. (2004) para, alternativamente ao tempo de atuação, determinar a experiência do profissional. Contudo, os autores observaram que cargos mais elevados muitas vezes são ocupados por profissionais que não tem experiência nas rotinas automatizadas e, portanto, a variável é insuficiente para determinar a experiência. Ainda assim, é uma variável que pode ser utilizada no estudo e sua análise de significância está representada na Figura 15 e pode ser localizada na Tabela 6 pelo código “SENIOR\_dummy”.

Outra variável de controle foi a percepção do usuário em relação à dificuldade com a tarefa. Ao estudar a TTD, Jensen et al. (2010) observaram que profissionais menos experientes consideram a tarefa realizada com apoio de IA mais difícil do que os profissionais mais experientes, e seria relevante identificar se haveria alguma relação com o tipo de dificuldade atribuída. No presente estudo, com base na literatura foram listadas algumas dificuldades associadas com a classificação tributária de produtos e mercadorias: a) busca pela legislação; b) interpretação da legislação; c) interpretação do texto descritivo do produto e d) quantidade de impostos incidentes sobre um produto.

A busca pela legislação de referência para a classificação é a principal dificuldade apontada pela literatura relacionada com a funcionalidade de IA oferecida pela Busca.Legal. As demais dificuldades apontadas embora sejam atribuíveis às rotinas tributárias, não são explicitamente atribuíveis à IA. Assim, no instrumento, a variável foi medida como uma *dummy*, sendo 1 a resposta para a busca pela legislação e 0 para as demais respostas. Esta variável de percepção do usuário em relação à dificuldade com a tarefa foi testada para avaliação de sua significância no capítulo 4 e tem seus resultados demonstrados na Figura 16 e pode ser localizado na Tabela 6 pelo código “DIFIC\_dummy”

O grau de participação da tecnologia, em geral, percebido pelos respondentes em suas rotinas foi utilizado por Hampton (2005) como variável de ajuste cognitivo. Segundo o autor, embora a literatura associe o grau de participação da tecnologia como medida para a confiança, ou TTD, essa é uma medida controversa pois a participação da tecnologia não indica necessariamente a disposição do usuário em incorporar as recomendações da IA. No presente estudo, apenas 18% consideraram baixa ou nula a participação da tecnologia nas rotinas tributárias, inclusive direciona responder o objetivo específico desta pesquisa, uma vez que os profissionais compreendem a utilidade e entendem que devem buscar por ela. Esta variável foi testada para entendermos sua significância no capítulo 4, Figura 17 e pode ser localizado na Tabela 6 pelo código “GRAU”

Em relação ao tempo de exercício profissional, Hampton (2005) sugeriu que a experiência do profissional, medida em relação ao uso da tecnologia, poderia ser avaliada com a proposição de um teste. No experimento realizado pelo autor, todos os participantes completaram um teste para estabelecer seu nível de conhecimento sobre o tema do experimento. O teste identificou níveis diferentes de complexidade das questões para avaliar a assertividade das respostas. Considerando as limitações de se avaliar a experiência dos profissionais apenas pelo teste, que poderia ser enviesado por um conjunto de fatores específicos do respondente (segmento da empresa, produtos, localidade, etc.), o critério de mensuração foi utilizado como variável de controle.

Para avaliação do conhecimento dos respondentes, deste estudo, foram propostas perguntas relacionadas com a teoria e prática da apuração das contribuições sociais, PIS e COFINS, tributos ligados à rotina de classificação fiscal automatizada pela IA da Busca.Legal. Os tributos foram escolhidos por serem federais, logo, mais abrangentes e a legislação mais comum.

Foram elaboradas três questões, sendo a primeira sobre os regimes tributários e alíquotas comuns (dificuldade = fácil), a segunda relacionada à possibilidade de apropriação de crédito ou não (dificuldade = intermediário) e a terceira, uma definição da tributação das contribuições sociais sobre dois produtos, açúcar mascavo e açúcar baunilha de 1kg (dificuldade = difícil). Apesar do pré-teste realizado, observou-se maior índice de erro na questão de dificuldade intermediária (45%) que na questão de dificuldade difícil (37%). O percentual de erro na questão de dificuldade fácil foi de 28%. Dessa forma, para mensuração dessa variável, foi estabelecido uma soma de

respostas corretas. Assim, quem errou todas as questões recebeu nota 0 e quem acertou todas as questões recebeu nota 3. O teste estatístico de significância dessa variável pode ser visualizado na Figura 20 e destacado na Tabela 6, como “CTRI”

No estudo teórico de Triki e Weisner (2014), os autores propõem que o estudo da TTD alcance a percepção dos profissionais da relação da tecnologia com as suas carreiras. Os autores sugerem a investigação da relação da dominância tecnologia com a performance profissional, avaliada em termos positivos, como: a) participação em projetos relevantes; b) reconhecimentos da liderança; c) promoções e; d) movimentação lateral. No caso de efeitos negativos, esses podem ser de natureza: a) desligamento, b) tarefa incompleta; c) perda de oportunidades (promoções, movimentações laterais).

No instrumento de coleta, os entrevistados foram questionados quanto a percepção de aspectos positivos ou negativos e, em seguida, foram incluídas duas questões: uma para avaliar se os impactos positivos estavam associados com o uso da tecnologia e outra para avaliar se os impactos negativos estavam associados com o uso da tecnologia. Para estas perguntas foi utilizada uma escala Likert de 7 pontos. O teste estatístico que mede a significância está representado na Figura 18 e 19 e pode ser localizado na Tabela 6 pelos códigos “AVALP” e “AVALN”.

**Tabela 6**  
**Descrição e métricas das variáveis**

Código	Descrição	Métrica
NOVO_dummy	Se é primeiro uso do sistema	0 - Não 1 – Sim
FEM_dummy	Se é do sexo feminino	0 - Não 1 – Sim
IDAD	Idade	1 - Entre 18 e 25 2 - Entre 26 e 35 3 - Entre 36 e 45 4 - Entre 46 e 55 5 - Acima de 55
FORASE_dummy	Localização do Respondente	0 – Sudente 1 – Outras regiões
SENIOR_dummy	Posição do Cargo	0 – Outro Assistente Fiscal Auxiliar Fiscal Analista Fiscal 1 - Especialista Fiscal Coordenador Fiscal Supervisor Fiscal Gerente Fiscal

Continua

		Conclusão
Código	Descrição	Métrica
ESP_dummy	Especialização	1 - Mínimo especialização na área tributária (contabilidade ou direito) 0 – Outras
EXP_M	Experiência	Média, considerando: Menor tempo de experiência = 1 Maior tempo de experiência = 6
FAMI_N	Familiaridade	Soma das Respostas, sendo 1 para cada Sim - (mínimo 0 – máximo 5)
TTD	Dominância	Soma das Respostas 1 – Sim (mínimo 0 – máximo 8)
DIFIC_dummy	A dificuldade é associada com a IA	1 - Busca pela legislação 0 – DEMAIS
GRAU	Grau de participação da tecnologia	0 – Nenhuma 1 - Baixa 2- Media 3 – Alta
AVALP	Impacto Positivo TI na performance profissional	Likert 7 pontos
AVALN	Impacto Negativo TI na performance profissional	Likert 7 pontos
CTRI	Conhecimento Tributário	Soma das Respostas corretas (mínimo 0 – máximo 3)

### 3.6 Validade interna e externa

Para Campbell (1957), a validade do quase-experimento dá-se pela preocupação em relação às variáveis não controláveis, as quais podem influenciar o experimento e, conseqüentemente, a forma de interpretação dos resultados. Segundo o autor, em relação à validade interna, a principal preocupação é demonstrar se as alterações observadas na variável dependente são de fato devidas ao efeito da variável independente e não a outras variáveis. Para isso, relaciona um conjunto e ameaças e propõe as medidas de controle para combatê-las. A Tabela 7 apresenta a relação de ameaças e as medidas adotadas no presente estudo. Logo, exprime esta definição.

Tabela 7  
Ameaças à validade interna

Ameaça	O que é	Medida de Controle
<b>Testando</b>	Instrumentos iguais para um mesmo entrevistado, de forma que se aprende as respostas	Haverá somente um tipo de questionário
<b>Maturação</b>	Efeito observado com o passar do tempo e não pela intervenção utilizada	Utilização de um grupo de controle - Possíveis ameaças serão tratadas como limitações deste estudo
<b>Instrumentação</b>	Falta de consistência no instrumento de medição	Pré-Teste realizado
<b>Regressão Estatística</b>	Realização da escolha de entrevistados que tenham se destacado	Conforme literatura anterior, foi estabelecido um número mínimo de 100 profissionais, alcançado.
<b>Seleção diferencial</b>	Utilização de grupos específicos, pré-formados	Os respondentes foram divididos em dois grupos: com experiência anterior no Busca. Legal e sem experiência anterior
<b>Interação seleção-maturação</b>	Interação entre os grupos experimentais e de controle	Experimento realizado individualmente, sem interação entre os participantes.
<b>Difusão do tratamento experimental</b>	Interação entre os grupos experimentais e de controle	Experimento realizado individualmente, sem interação entre os participantes.
<b>Rivalidade compensatória pelo grupo de controle</b>	Interação entre os grupos experimentais e de controle	Experimento realizado individualmente, sem interação entre os participantes.
<b>Desmoralização ressentida do grupo de controle</b>	Interação entre os grupos experimentais e de controle	Grupo de controle e experimento estarão em níveis diferentes de conhecimento sobre a IA.

Nota: Fonte: Adaptado de “*Factors relevant to the validity of experiments in social settings*”, de Campbell. 1957.

Quanto à validade externa do estudo, está relacionada à capacidade de generalização dos resultados do experimento para o mundo real; logo, trata-se da capacidade de prever se os resultados encontrados, em uma amostra, são significantes para uma população alvo (Campbell, 1957). A Tabela 8 compõe fatores que representam ameaça à validade externa de um experimento e a forma como foram tratados para garantir os resultados.

Tabela 8  
Validade externa

<b>Validade Externa - Da população</b>		
<b>Ameaça</b>	<b>O que é</b>	<b>Medida de Controle</b>
<b>Extensão da generalização da amostra para a população alvo</b>	Riscos das médias das amostras serem diferentes das médias da população alvo	Amostra terá um comportamento próximo à população alvo. Possíveis ameaças serão tratadas como limitações deste estudo.
<b>Extensão da generalização da amostra para a população alvo</b>	Riscos das médias das amostras serem diferentes das médias da população alvo	Amostra terá um comportamento próximo à população alvo. Possíveis ameaças serão tratadas como limitações deste estudo.
<b>Extensão em que as variáveis amostrais interagem com efeitos do tratamento</b>	Características próprias da amostragem podem interferir no resultado	Amostra compatível com a população alvo. Possíveis ameaças serão tratadas como limitações deste estudo.
<b>Validade Externa - Ecológicas ou Ambientais</b>		
<b>Descrição explícita do tratamento experimental</b>	Procedimentos experimentais não descritos de forma que se possa replicar o experimento	O protocolo utilizado foi explicitado em todos os detalhes possíveis
<b>Interferência de tratamentos múltiplos</b>	Mesmo sujeito recebe diversos tratamentos	Apenas um tratamento foi realizado
<b>Efeito Hawthorne</b>	Outras variáveis explicando os resultados - efeito placebo	Controle e experimento serão de ambientes distintos
<b>Efeito de novidade e rompimento</b>	Intervenção surtirá efeito por ser pioneiro no ramo	Trabalho será original no Brasil, buscando motivação dos entrevistados
<b>Efeito experimentador</b>	Efeitos se realizarão por conta da amostra ou pesquisador	Será evitada interferência na pesquisa
<b>Interação de história e efeitos do tratamento</b>	Efeitos serão positivos por influências externas	Não há trabalhos no Brasil medindo confiança no uso de IA na área fiscal
<b>Mensuração de variáveis dependentes</b>	Diferentes formas de aplicar uma entrevista, gerando diferentes dados de formas distintas	O mesmo questionário foi submetido a todos os participantes do estudo
<b>Interação do tempo de mensuração e efeitos do tratamento</b>	Risco de perder o efeito de visto à demora em coletar os dados da entrevista	Compilação dos dados realizada logo após a conclusão das coletas

Nota. Fonte: Adaptado de "Factors relevant to the validity of experiments in social settings", de Campbell. 1957.

Assim, o desenho experimental utilizado, neste estudo levou em consideração as ameaças e buscou mitigar seus impactos sobre os entrevistados e até mesmo ao ambiente experimental. Diversas variáveis, potencialmente ameaçadoras à realização da pesquisa, são externas e não passíveis de controle e serão consideradas como limitações no presente estudo.



## 4 Análises dos Resultados

Foram analisadas as transcrições das 144 respostas à *survey*, representando os profissionais tributários no Brasil.

Ao término da análise de conteúdo, foi identificado se a experiência, a especialização dos profissionais tributários e sua familiaridade com tecnologias da informação impacta o uso de ferramenta com IA, no que se refere à confiança.

### 4.1 Análise demográfica

Nossa amostra original consistiu em 158 respondentes que preencheram o formulário eletrônico, no entanto, apenas 144 respostas puderam ser aproveitadas. Os participantes que não completaram a pesquisa foram descartados. A amostra final foi composta por 68 profissionais sem experiência anterior com o Busca.Legal (grupo de controle) e 76 que já tiveram contato para efeito do experimento (grupo de tratamento). A Tabela 9 resume as informações demográficas dos dois grupos de participantes. O grupo experimental é mais jovem (75% com idade até 35 anos contra 53% do grupo de controle) e, possivelmente por esse motivo, atua em cargos mais técnicos e menos gerenciais (24% atuam em cargos de especialista, coordenador, supervisor e gerente contra 51% no grupo de controle).

Nota-se no presente trabalho que 58% dos respondentes eram mulheres. Comparativamente, o estudo de Noga e Arnold (2002), realizado com 79 estudantes, apresentou uma média de 50% de mulheres, enquanto o trabalho de Malaescu e Sutton (2015) foi de 46% de mulheres. Quanto a idade, no estudo de Noga e Arnold (2002), a média de idade dos respondentes era de 24 anos de idade enquanto no estudo de Jensen et al (2010) era de 21,5 anos. No presente trabalho 72% dos respondentes no presente estudo indicaram idade superior a 24 anos. Quanto a ocupação profissional, no estudo de Noga e Arnold (2002) apenas 27% eram profissionais com experiência na área tributária, enquanto 100% dos respondentes do estudo eram profissionais com diferentes ocupações.

Tabela 9  
Análise Demográfica

Atributo	Descrição	Gr. Controle		Gr. Experimental		Total	
N		68		76		144	
Sexo	Masculino	39	57%	22	29%	61	42%
	Feminino	29	43%	54	71%	83	58%
Idade	Entre 18 e 25	12	18%	28	37%	40	28%
	Entre 26 e 35	24	35%	29	38%	53	37%
	Entre 36 e 45	19	28%	14	18%	33	23%
	Entre 46 e 55	11	16%	5	7%	16	11%
	Acima de 55	2	3%	0	0%	2	1%
	Região	Sul	6	9%	10	13%	16
	Sudeste	53	78%	57	75%	110	76%
	Centro-Oeste	5	7%	3	4%	8	6%
	Nordeste	2	3%	1	1%	3	2%
	Norte	2	3%	5	7%	7	5%
Cargo	Outro	2	3%	4	5%	6	4%
	Assistente Fiscal	9	13%	15	20%	24	17%
	Auxiliar Fiscal	5	7%	10	13%	15	10%
	Analista Fiscal	17	25%	29	38%	46	32%
	Especialista Fiscal	18	26%	9	12%	27	19%
	Coordenador Fiscal	6	9%	4	5%	10	7%
	Supervisor Fiscal	6	9%	0	0%	6	4%
	Gerente Fiscal	5	7%	5	7%	10	7%

## 4.2 Estatística descritiva

Inicialmente, variáveis independentes, como a experiência (H1), especialização (H2), familiaridade (H3) e a variável dependente, como a TTD foram analisadas a partir da estatística descritiva.

A Tabela 10 detalha os constructos de interesse com seus correspondentes itens de medição.

Tabela 10  
**Constructos versus itens de medição**

	Média	Erro padrão	Mediana	Modo	Desvio padrão	Variância da amostra	Curtose	Assimetria	Nível de confiança (95,0%)
<i>NOVO_dummy</i>	0,528	0,042	1,000	1,000	0,501	0,251	-2,016	-0,112	0,083
<i>FEM_dummy</i>	0,576	0,041	1,000	1,000	0,496	0,246	-1,929	-0,312	0,082
<i>IDAD</i>	2,215	0,085	2,000	2,000	1,018	1,037	-0,471	0,522	0,168
<i>FORASE_dummy</i>	0,236	0,036	-	-	0,426	0,182	-0,429	1,256	0,070
<i>SENIOR_dummy</i>	0,368	0,040	-	-	0,484	0,234	-1,718	0,553	0,080
<i>ESP_dummy</i>	0,410	0,041	-	-	0,493	0,244	-1,889	0,371	0,081
<i>EXP_M</i>	3,688	0,148	3,750	6,000	1,771	3,137	-1,455	-0,027	0,292
<i>FAMI_N</i>	4,451	0,089	5,000	5,000	1,070	1,144	5,788	-2,409	0,176
<i>TTD</i>	7,042	0,153	8,000	8,000	1,832	3,355	7,291	-2,680	0,302
<i>FREQ_dummy</i>	0,271	0,037	-	-	0,446	0,199	-0,927	1,042	0,073
<i>DIFIC_dummy</i>	0,840	0,031	1,000	1,000	0,368	0,135	1,545	-1,877	0,061
<i>GRAU</i>	2,319	0,077	3,000	3,000	0,929	0,862	0,427	-1,212	0,153
<i>AVALP</i>	5,368	0,137	6,000	7,000	1,642	2,696	0,817	-1,108	0,270
<i>AVALN</i>	3,813	0,163	4,000	4,000	1,950	3,804	-1,130	-0,099	0,321
<i>CTRI</i>	1,882	0,082	2,000	3,000	0,986	0,972	-1,027	-0,337	0,162

Testamos a confiabilidade interna das escalas com base nos dados da Tabela 9 e o resultado foi de 0,917, utilizando a metodologia de Alpha de Cronbach. O resultado maior que 0,70 é considerado normal e acima de 0,9, excelente.

### 4.3 Análise estatística dos dados

Este experimento mediu as variáveis independentes como a experiência (H1), especialização (H2) e familiaridade (H3), testando-as contra a variável dependente TTD. Todos os testes estatísticos e gráficos desta seção foram executados no software SPSS V25 e foram considerados significantes, os dados, com nível descritivo menor que 5% (valor de  $p < 0,05$ ).

O presente estudo busca investigar a dominância tecnológica, no uso de ferramentas com IA, nas rotinas tributárias, assim, o objetivo do presente trabalho é responder a seguinte pergunta: A experiência, especialização e familiaridade de profissionais tributários com tecnologias da informação afeta sua confiança em ferramentas com inteligência artificial?

Para responder a pergunta testamos a dominância da tecnologia no grupo controle e grupo de tratamento e, na sequência, testamos a TTD com as variáveis independentes como experiência, especialização e familiaridade.

#### 4.3.1 Dominância nos grupos

Para responder a pergunta proposta, temos uma amostra de 144 respondentes, sendo 68 alocadas no grupo controle e 76 no grupo de tratamento, bem como a variável dependente, a dominância, foi testada em vários recortes.

Para entender como os respondentes se sentem com respeito à dominância tecnológica, no geral, analisamos a distribuição desta variável para os dois grupos, que podem ser visualizadas nas Figuras 3 e 4.

		Frequência	Porcentagem	Porcentagem válida	Porcentagem acumulativa
Válido	,00	1	1,5	1,5	1,5
	4,00	1	1,5	1,5	2,9
	5,00	4	5,9	5,9	8,8
	6,00	7	10,3	10,3	19,1
	7,00	9	13,2	13,2	32,4
	8,00	46	67,6	67,6	100,0
	Total	68	100,0	100,0	

a. GRUPO = Controle

**Figura 3.** Distribuição para grupo de controle.

Este grupo, cujo o uso da ferramenta Busca.Legal, que possui recursos com IA, se dá pela primeira vez, apresenta 80,8% dos respondentes na alta dominância (respostas 7 e 8), de forma que os profissionais respondentes na dominância moderada são apenas 16,2%, enquanto que a baixa dominância praticamente não existe neste grupo, o de controle.


		Frequência	Porcentagem	Porcentagem válida	Porcentagem acumulativa
Válido	,00	5	6,6	6,6	6,6
	2,00	1	1,3	1,3	7,9
	3,00	1	1,3	1,3	9,2
	5,00	4	5,3	5,3	14,5
	6,00	7	9,2	9,2	23,7
	7,00	14	18,4	18,4	42,1
	8,00	44	57,9	57,9	100,0
	Total	76	100,0	100,0	

a. GRUPO = Experimento

**Figura 4.** Distribuição para grupo de tratamento.

No grupo de tratamento, composto por usuários da Ferramenta Busca.Legal, 76,3% das respostas encontram-se no nível de alta dominância, 14,5% na dominância moderada e 9,2% na faixa de baixa dominância.

De forma individual, o grupo controle tem maior dominância do que o grupo de tratamento, porém, estatisticamente, não é possível afirmar ainda qual grupo tem maior dominância à tecnologias, uma vez que os percentuais divergem de forma mínima. No sentido de avançarmos na identificação de qual grupo tem a maior dominância, propomos a elaboração do teste de média com barras de erros, que é um dos conceitos importantes dentro dos testes de hipóteses na estatística, por ser utilizado para dissipar incertezas, que pode ser evidenciado na Figura 5.



**Figura 5.** Média com barras de erros para dominância por grupo: Controle e tratamento.

Na Figura 5, em linhas gerais, continuamos vendo que o grupo controle está em um patamar mais elevado comparado ao grupo tratamento, sendo a diferença entre eles de 0,51, porém, estatisticamente, a variação pode ser não relevante para determinarmos a dominância em algum grupo, assim esta tendência precisa ser confirmada por um teste de hipóteses para que possamos avaliar se a diferença é significativa entre os grupos ou não.

O teste de hipótese, preferencialmente, seria um teste paramétrico, no caso um *t-student*, para as duas amostras (controle e tratamento) independentes. Os testes paramétricos exigem que as amostras cumpram algumas suposições, neste caso: normalidade das distribuições e homogeneidade das variâncias (variâncias iguais), são as mais importantes.

Assim, precisamos executar testes para verificação das suposições acima. Para normalidade optamos pelo teste de *Kolmogorv-Smirnov* (indicado para amostras maiores que 50). O teste de normalidade a seguir testará duas hipóteses, sendo:

H0: As amostras seguem a distribuição normal

H1: As amostras não seguem a distribuição normal

GRUPO	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estatística	df	Sig.	Estatística	df	Sig.
Dominância						
Controle	,373	68	,000	,578	68	,000
Experimento	,300	76	,000	,600	76	,000

a. Correlação de Significância de Lilliefors

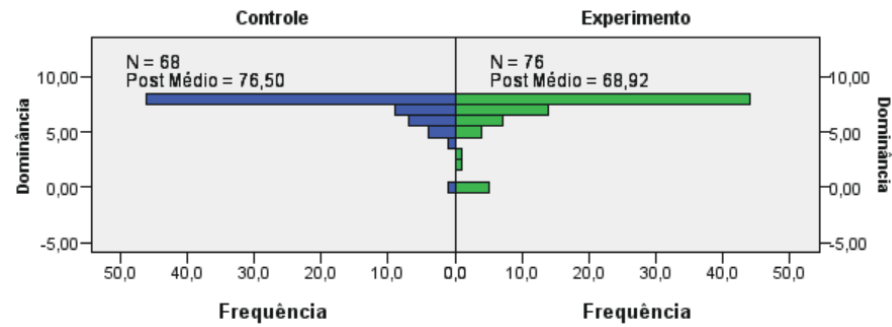
**Figura 6.** Teste de Normalidade.

O teste de normalidade de Kolmogorv-Smirnov e Shapiro-Wilk mostraram-se significativos, de forma que rejeitamos H0 ( $p\text{-valor} < 0,001$ ), considerando  $\alpha=0$ , portanto a normalidade não é conferida para os dois grupos, constatando, então, que as amostras não seguem uma distribuição normal (H1).

Uma vez que não há normalidade das amostras, podemos buscar um teste não paramétrico alternativo ao teste *t de student*, o teste de *Mann-Whitney*, uma vez que este não exige conhecimento da distribuição, sendo um teste alternativo, embora suas hipóteses não sejam exatamente as mesmas (*t student* = média e *withney* = distribuição), uma vez que agora estamos testando as distribuições. Assim, testaremos as hipóteses listadas abaixo:

H0 as distribuições permitem uma dominância igual

H1 as distribuições não permitem uma dominância igual



	Hipótese nula	Teste	Sig.	Decisão
1	A distribuição de Dominância é a mesma entre as categorias de GRUPO.	Teste U de Mann-Whitney de amostras independentes	,209	Reter a hipótese nula.

Figura 7. Teste de Mann-Whitney - comparação de distribuições.

Os resultados indicam que devemos reter a H0 pois o p-valor = 0,209. Assim, reter a hipótese nula, entendemos que a distribuição da dominância é a mesma para os grupos controle e tratamento, considerando  $\alpha=0,05$ .

#### 4.3.2 Dominância por especialização

O próximo teste tem a função de confirmar ou rejeitar a H2, ou seja, confirmar se o profissional tributário com menor especialização possui mais dominância em ferramentas com IA. Teste representado na Figura 8.

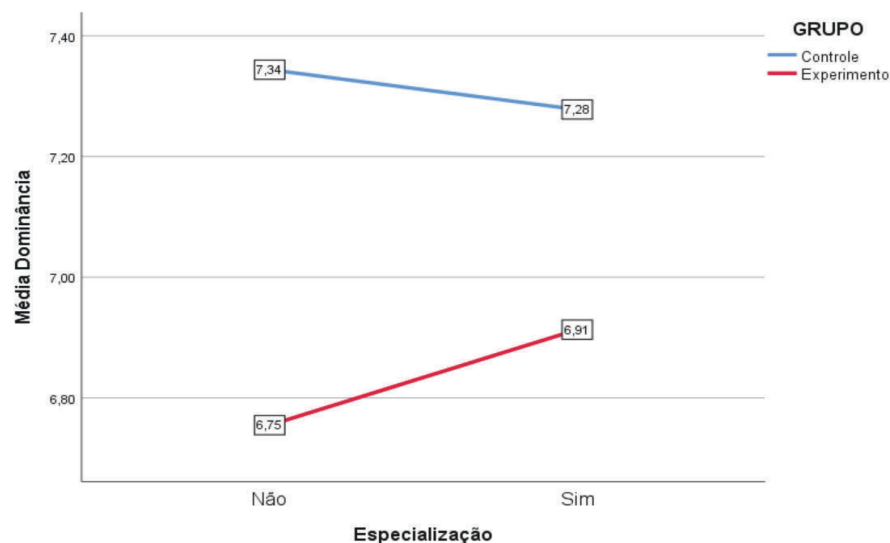


Figura 8. Dominância versus Especialização.

Na Figura 9, até temos mudanças de comportamento para os dois grupos, enquanto os não especializados do grupo tratamento apresentam um leve declínio à

dominância, contrariando a H2 deste estudo, o grupo controle, para os também não especializados, mostra uma leve elevação à dominância, reagindo conforme a H2 deste estudo. Estas variações podem ser significativas ou devida ao acaso, de forma que para esclarecermos este impasse, aplicaremos o teste two-way ANOVA, que testará as seguintes hipóteses:

H1: Existe efeito de interação grupo *versus* especialização?

H2: Existe efeito de Grupo?

H3: Existe efeito de Especialização?

Variável dependente: Dominância

Origem	Tipo III Soma dos Quadrados	gl	Quadrado Médio	F	Sig.
Modelo corrigido	9,672 <sup>a</sup>	3	3,224	,960	,414
Intercepto	6593,538	1	6593,538	1963,705	,000
GRUPO	7,495	1	7,495	2,232	,137
ESP	,070	1	,070	,021	,885
GRUPO * ESP	,415	1	,415	,123	,726
Erro	470,078	140	3,358		
Total	7620,000	144			
Total corrigido	479,750	143			

**Figura 9.** Teste de Two-Way ANOVA – Especialização.

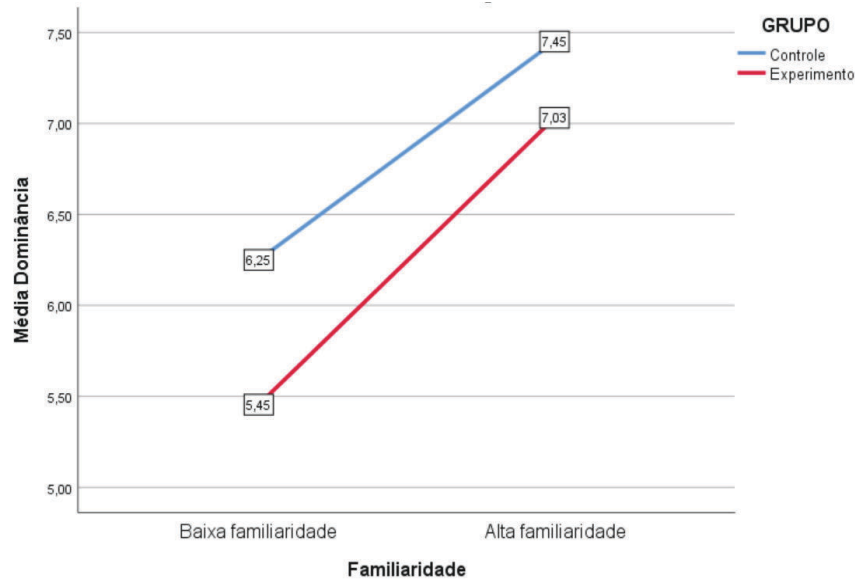
O teste ANOVA, dá visibilidade de não haver qualquer efeito ou interação, ou seja, a variável independente especialização não é capaz de mover as médias da dominância, isso mesmo que o teste fosse um não paramétrico, já que os testes paramétricos são mais sensíveis. Assim, temos os seguintes p-valor:

- de 0,726 para interação entre grupo e especialização;
- de 0,885 para o efeito de especialização, e
- de 0,137 para o efeito de grupo.

#### **4.3.3 Dominância por familiaridade**

O próximo teste tem a função de confirmar ou rejeitar a H3, ou seja, confirmar, se quanto maior a familiaridade do profissional com tecnologias aplicadas à gestão tributária, maior é a dominância da IA. Teste representado na Figura 10.





**Figura 10.** Dominância *versus* Familiaridade.

Neste teste, os perfis dos respondentes indicam mudanças de comportamento para os dois grupos e no mesmo sentido, tendo em vista que os dados demonstram que, em ambos os grupos, a alta familiaridade, traz um a maior dominância, ou seja, os profissionais já demonstram mais aptidão em relação àqueles que ainda tem pouca familiaridade com tecnologias. Entretanto, estaticamente, perfis paralelos não são indícios de interação, de forma que executaremos, também, uma two-way ANOVA, para confirmar nossas suspeitas, trabalhando as hipóteses a seguir:

H1: Existe efeito de interação grupo *versus* familiaridade?

H2: Existe efeito de Grupo?

H3: Existe efeito de Familiaridade?

Variável dependente: Dominância

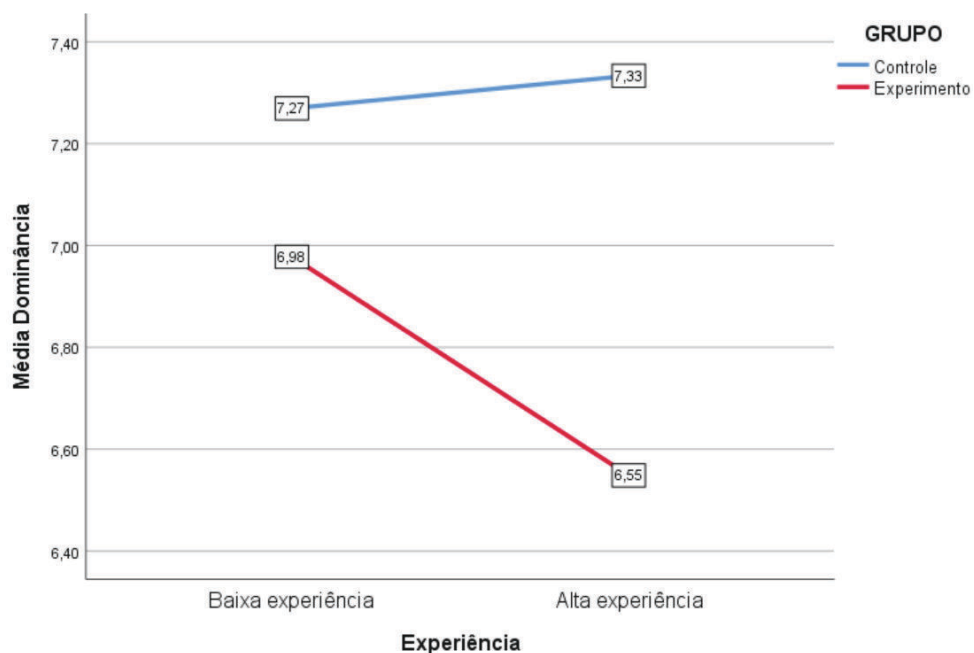
Origem	Tipo III Soma dos Quadrados	gl	Quadrado Médio	F	Sig.
Modelo corrigido	42,734 <sup>a</sup>	3	14,245	4,563	,004
Intercepto	2765,243	1	2765,243	885,858	,000
GRUPO	5,950	1	5,950	1,906	,170
FAMILIARIDADE	31,083	1	31,083	9,958	,002
GRUPO * FAMILIARIDADE	,571	1	,571	,183	,670
Erro	437,016	140	3,122		
Total	7620,000	144			
Total corrigido	479,750	143			

**Figura 11.** Teste de Two-Way ANOVA - Familiaridade

Em uma two-way ANOVA devemos primeiramente avaliar o efeito de interação, que neste caso é não significativo ( $p\text{-valor}=0,670$ ), ou seja, grupo e familiaridade, conjuntamente, não afetam a dominância média. Como não temos efeito de interação, podemos usar a mesma Tabela para avaliar os efeitos principais de Grupo e Familiaridade, individualmente, de forma que o efeito de grupo é não significativo ( $p\text{-valor}=0,170$ ), como já havia sido demonstrado anteriormente, porém a variável familiaridade apresenta efeito significativo ( $p\text{-valor}=0,002$ ), demonstrando que as médias de dominância se alteram quando mudamos de categoria de Familiaridade (baixa, média e alta), no caso quanto maior a familiaridade maior a dominância.

#### 4.3.4 Dominância por experiência

O próximo teste tem a função de confirmar ou rejeitar a H1, ou seja, confirmar se quanto maior a experiência do profissional com tecnologias aplicadas à gestão tributária, menor é a dominância da IA. Teste representado na Figura 12.



**Figura 12.** Dominância *versus* Experiência

Na Figura 12, vemos mudanças de comportamento para os dois grupos, enquanto os profissionais com baixa experiência do grupo tratamento apresentam uma elevação à dominância, aprovando a H1 deste estudo, o grupo controle, para os também não experientes, mostra um leve declínio à não dominância, contrariando a H1. Estas variações podem ser significativas ou devida ao acaso, de forma que para esclarecermos este impasse, aplicaremos o teste two-way ANOVA, que testará as seguintes hipóteses

H1: Existe efeito de interação grupo *versus* experiência?

H2: Existe efeito de Grupo?

H3: Existe efeito de Experiência?

Variável dependente: Dominância

Origem	Tipo III Soma dos Quadrados	gl	Quadrado Médio	F	Sig.
Modelo corrigido	12,646 <sup>a</sup>	3	4,215	1,263	,289
Intercepto	6777,013	1	6777,013	2031,201	,000
GRUPO	9,924	1	9,924	2,974	,087
EXPERIENCIA	1,143	1	1,143	,343	,559
GRUPO * EXPERIENCIA	2,086	1	2,086	,625	,430
Erro	467,104	140	3,336		
Total	7620,000	144			
Total corrigido	479,750	143			

**Figura 13.** Teste de Two-Way ANOVA - Experiência

O teste ANOVA, dá visibilidade de não haver qualquer efeito ou interação, ou seja, a variável independente experiência não é capaz de mover as médias da dominância, isso mesmo que o teste fosse um não paramétrico, já que os testes paramétricos são mais sensíveis. Assim, temos os seguintes p-valor:

- d) de 0,430 para interação entre grupo e especialização;
- e) de 0,559 para o efeito de especialização, e
- f) de 0,87 para o efeito de grupo.

#### 4.3.6 Testes adicionais

Como não foi observada distribuição normal para a variável TTD nas diversas categorias das variáveis independentes e variáveis de controles explicativas, optamos por testes não-paramétricos. Para variáveis grupo com 2 categorias, foi executado o teste de Mann-Whitney Para variáveis grupo com mais de 2 categorias, foi executado o teste de Kruskal-Wallis, bem como foi adotado  $\alpha=0,05$  para todos os testes, ou seja, haverá significância sempre que tivermos p-valor  $< 0,05$ .

Das variáveis de controle explicativas contidas na *survey*, selecionamos: idade, senioridade de cargo, dificuldades associadas à IA, grau de participação da tecnologia, avaliações negativas e positivas do uso e não uso e avaliação de performance técnica.

### Resumo de Teste de Hipótese

	Hipótese nula	Teste	Sig.	Decisão
1	A distribuição de TDD é a mesma entre as categorias de IDAD.	Teste de Kruskal-Wallis de Amostras Independentes	,053	Reter a hipótese nula.

Figura 14. Teste de significância – Variável idade

### Resumo de Teste de Hipótese

	Hipótese nula	Teste	Sig.	Decisão
1	A distribuição de TDD é a mesma entre as categorias de SENIOR_dummy.	Teste U de Mann-Whitney de amostras independentes	,941	Reter a hipótese nula.

Figura 15. Teste de significância – Variável Senioridade de cargo

### Resumo de Teste de Hipótese

	Hipótese nula	Teste	Sig.	Decisão
1	A distribuição de TDD é a mesma entre as categorias de DIFIC_dummy.	Teste U de Mann-Whitney de amostras independentes	,378	Reter a hipótese nula.

Figura 16. Teste de significância – Variável Dificuldade (*busca por legislação*)

### Resumo de Teste de Hipótese

	Hipótese nula	Teste	Sig.	Decisão
1	A distribuição de TDD é a mesma entre as categorias de GRAU.	Teste de Kruskal-Wallis de Amostras Independentes	,133	Reter a hipótese nula.

Figura 17. Teste de significância – Grau de participação da IA

### Resumo de Teste de Hipótese

	Hipótese nula	Teste	Sig.	Decisão
1	A distribuição de TDD é a mesma entre as categorias de AVALP.	Teste de Kruskal-Wallis de Amostras Independentes	,189	Reter a hipótese nula.

Figura 18. Teste de significância – Avaliações positivas com uso da IA

	Hipótese nula	Teste	Sig.	Decisão
1	A distribuição de TDD é a mesma entre as categorias de AVALN.	Teste de Kruskal-Wallis de Amostras Independentes	,253	Reter a hipótese nula.

**Figura 19.** Teste de significância – Avaliações negativas pelo não uso da IA

	Hipótese nula	Teste	Sig.	Decisão
1	A distribuição de TDD é a mesma entre as categorias de CTRL.	Teste de Kruskal-Wallis de Amostras Independentes	,471	Reter a hipótese nula.

**Figura 20.** Teste de significância – Avaliação técnica

Como pode-se ver as demais variáveis, também, não deram significância, uma vez que o p-valor deram superior a p-valor  $< 0,05$ .

#### 4.3.7 Comparação com resultados anteriores

O presente estudo, considerou as pesquisas anteriores (Hampton, 2005; Jensen et al, 2010; Mălăescu & Sutton, 2015 & Noga & Arnold, 2002) que testaram o nível de familiaridade, experiência e especialização dos profissionais apoiadas por uma ferramenta com tecnologia, por exemplo, a IA, no entanto, as percepções dos usuários sobre tais itens tiveram a possibilidade de serem medidos a partir do estudo de Arnold e Sutton (1998). Tais estudos podem ser vistos em sua essência, de forma sumária, na Tabela 11.

Tabela11  
Estudos Anteriores

Autor (es)	Hipóteses	Constructos	Resultados
Malaescu e Sutton (2015)	<p>H1 um auxílio restritivo à decisão proporcionará maiores reduções na carga cognitiva para tomadores de decisão mais iniciantes, enquanto induz aumentos na carga cognitiva para tomadores de decisão mais experientes.</p> <p>H2a. Usuários iniciantes perceberão um auxílio à decisão mais restritivo como mais útil do que um menos restritivo auxílio à decisão.</p>	Experiência	<p>Preferência de profissionais experientes por AID menos restritivos (mais dominância) e profissionais menos experientes por mais restritivos (menos dominância)</p>
	<p>H2b. Usuários experientes perceberão um auxílio à decisão menos restritivo como mais útil do que um mais restritivo auxílio à decisão.</p> <p>H3a. É mais provável que usuários iniciantes desejem reutilizar um auxílio à decisão mais restritivo, em vez de um menos restritivo.</p> <p>H3b. Usuários experientes têm mais chances de reutilizar um auxílio à decisão menos restritivo, em vez de um restritivo.</p>		<p>Experiência: Usuários iniciantes com mais dominância e usuários não iniciantes com menos dominância.</p>
Hampton (2005)	<p>H1a. Quando a experiência da tarefa é baixa, há uma relação positiva entre a experiência da tarefa e Dependência da AID</p>	Experiência Complexidade Familiaridade	<p>Complexidade: Usuários experientes e não experientes demonstram maior dominância da IDA ao avaliar tarefas complexas versus tarefas simples.</p>
	<p>H1b. À medida que a experiência da tarefa aumenta de níveis baixos para moderado ou alto, a relação positiva entre a experiência da tarefa e a dependência da AID diminuirão.</p>		<p>Familiaridade: Não houve suporte para o efeito previsto da familiaridade da AID</p>
	<p>H2. Quando a experiência da tarefa é moderada a alta, existe uma relação positiva entre altos níveis de complexidade de tarefas e dependência da AID.</p>		
	<p>H3 quando a experiência e a complexidade da tarefa são moderadas a altas, há uma relação positiva entre níveis moderados a altos de familiaridade e confiança da AID.</p>		
	<p>H4 quando a experiência, a complexidade e a familiaridade da AID são moderadas a altas, existe uma relação positiva entre níveis moderados a altos de ajuste cognitivo e dependência da AID.</p>		
<p>H5 baixos níveis de experiência em tarefas estão associados positivamente à dependência da AID. Simultaneamente níveis moderados a altos de experiência, complexidade de tarefas, familiaridade da AID e ajuste cognitivo estão associados positivamente à dependência da AID.</p>			

Jensen et al (2010).	<p>H1: as avaliações dos iniciantes serão menos diferentes das recomendações da ajuda do que as avaliações dos profissionais</p> <p>H2: A avaliação de credibilidade assistida por iniciantes será mais precisa do que avaliação sem auxílio por novatos.</p> <p>H3a: Profissionais são mais propensos do que iniciantes a acessar explicações gerado pelo auxílio à decisão.</p> <p>H3b: Profissionais que usam explicações geradas pelo auxílio à decisão têm maior probabilidade de aderir à recomendação do auxílio à decisão.</p> <p>H4: A avaliação de credibilidade assistida por profissionais será mais precisa do que a avaliação sem auxílio de profissionais.</p> <p>H5: Haverá uma diferença na avaliação da credibilidade auxiliada. Precisão não suportada entre iniciantes e profissionais.</p>	Visão Cognitiva Uso da decisão	<p>Profissionais e novatos melhoraram sua precisão da avaliação através do uso de tecnologia na tomada de decisão.</p> <p>Iniciantes eram mais dependentes da tecnologia do que os profissionais. No entanto, ao contrário do TTD, não houve diferença significativa na maneira como novatos e profissionais interagiram com o sistema, e o auxílio à decisão não foi mais benéfico para os profissionais. Novatos e profissionais frequentemente desconsideram as recomendações da ajuda, e, em muitos casos, os profissionais não viam explicações coerentes quando a sugestão de decisão por meio da tecnologia contradiziam suas avaliações.</p>
Noga & Arnold, 2002	<p>H1: Ao preencher uma declaração de imposto manualmente, os preparadores fiscais experientes terão um desempenho melhor do que os preparadores fiscais iniciantes.</p> <p>H2: Ao usar um TDSS para ajudar na preparação da declaração de imposto, os preparadores de imposto experientes serão mais eficientes e mais precisos do que os preparadores de imposto iniciantes.</p> <p>Hipótese 3: O uso de um TDSS reduzirá o tempo necessário para concluir uma declaração de imposto</p>	Experiência Especialização	<p>O uso de um TDSS ajudará tanto os novatos e usuários experientes na tomada de decisões, resultando em um nível mais alto de conformidade tributária.</p> <p>Embora um TDSS seja útil, ele pode fazer muito. Os usuários precisam ter uma compreensão do sistema tributário e alguma familiaridade com as informações tributárias</p> <p>Se o preparador não tiver experiência fiscal geral, é improvável que o usuário tome as decisões necessárias para preparar uma obrigação acessória com a assistência do software. Infelizmente, a natureza colaborativa do software pode dar ao usuário um senso de excesso de confiança no passivo fiscal.</p>

O presente estudo, quando comparado às hipóteses dos estudos citados anteriormente, traz similaridade estatística somente em relação à H3, onde determina que quanto maior for a familiaridade do grupo com tecnologias, maior é a dominância, logo, confirmando nossa hipótese de estudo.

Em relação às demais hipóteses H1 e H2, com base nos resultados da metodologia do ANOVA, para este grupo de respondente, independente se controle ou tratamento, rejeitamos as hipóteses, visto que o teste nos retornou que não há

qualquer efeito ou interação (impacto) da experiência e da especialização com a dominância, ou seja, elas não são capazes de moverem as médias da dominância.



## 5 Conclusões

O presente estudo reforça por meio das variáveis testadas a importância da IA para área contábil e tributária, bem como evidencia o quanto o profissional da área já reconhece as vantagens e aplicabilidade de inovações tecnológicas na área, uma vez que 82% dos respondentes entendem que a tecnologia tem impacto relevante na rotina tributária, ficando alinhado com parte do objetivo deste estudo que é investigar o impacto da experiência, a especialização e a familiaridade do profissional tributário brasileiro com uso de novas tecnologias e sua confiança nos sistemas de IA.

Para evidenciarmos a aplicabilidade e testarmos as três hipóteses deste estudo, adotamos o cenário de classificação fiscal de mercadorias e/ou produtos, uma vez que é conhecido por suas ambiguidades, complexidades e volume no que se refere à legislações que, inclusive, é evidenciada na *survey*, já que 87% respondentes relatam que a maior dificuldade com relação à análise de tributação sobre produtos/mercadorias é a busca e interpretação da Legislação.

Por conta destas dificuldades e da característica técnica deste processo de análise, uma ferramenta com IA, faz com que os profissionais vejam valor no uso e em seus resultados, pois entendem que a relação entre um NCM e a economia tributária é, além de uma atividade transacional, uma atividade estratégica, já que impacta no cálculo dos impostos, além de compor informações das mais variadas obrigações acessórias e de incentivos fiscais existentes na área. A classificação pode definir, por exemplo, se a empresa vai fazer uma importação pagando 2% ou 20% de impostos, logo, dependendo do volume importado, esse valor pode ser muito significativo, tanto em ganhos quanto em perdas, sem falar nos riscos de exposição fiscal.

As ferramentas tecnológicas, também denominadas de auxílios inteligentes à decisão (IDAs) e neste estudo representado pelo Busca.Legal, em suma, são projetados para capturar e disseminar o conhecimento de usuários experientes para uso generalizado por outros usuários, inclusive, iniciantes, ou seja, facilitam o treinamento de iniciantes, bem como permitem que tomem decisões que se aproximam ou se iguale à qualidade dos tomadores de decisão experientes. O uso de tecnologias na área tributária é mostrado consistentemente para aumentar a qualidade, *compliance* e a eficiência da decisão.

No entanto, para obter os benefícios do uso de tecnologias na área contábil tributária, o profissional deve ter confiança (dominância) na ferramenta. Pesquisadores de contabilidade conduziram numerosos estudos, relatados durante a elaboração deste estudo, para entender o potencial das tecnologias inseridas na rotina tributária, usando como base para seus estudos a teoria da dominância tecnológica (TTD) e suas variáveis, como a experiência, especialização, complexidade da tarefa, familiaridade com tecnologia e ajuste cognitivo.

Este estudo testa empiricamente três variáveis das quatro proposições da TTD (experiência, familiaridade e especialização) e os resultados da pesquisa podem ser visto nos dois grupos do experimento (*controle* = primeiro acesso na ferramenta e *tratamento* = clientes da ferramenta). Numa visão geral do cenário testado, o grupo controle, sob a ótica das três variáveis, tem maior dominância que o grupo de tratamento, o que pode se justificar pela percepção de valorização da ferramenta frente suas atividades diárias de forma manual (sem uso da IA), correlacionando com parte do objetivo deste estudo que é identificar a percepção do profissional em relação à eficiência de rotinas tributárias pós-implementação de ferramentas que fazem uso de IA.

No tocante ao teste individual das variáveis, familiaridade (H3) é a única variável das três que está positivamente associada à dominância da tecnologia ( $p$ -valor=0,002), de forma que os testes afirmam que a familiaridade, por si só, pode induzir dominância quando da mudança de categoria (baixa, média e alta), logo, quanto maior a familiaridade maior a dominância.

Em relação às demais hipóteses (H1 e H2), os testes estatísticos nos retornaram que os dados não são significativos já que ultrapassam o nível descritivo menor que 5% (valor de  $p < 0,05$ ), porém sob a ótica da estatística descritiva, percebemos alguns resultados, que serão descritos a seguir:

Com relação à variável experiência, os profissionais do grupo tratamento confirmam nossa H1, visto que os que os mais experientes na área tributária tem menos dominância da tecnologia, ao analisar os resultados de uma ferramenta com IA, o que se explica pelo fato de serem bastante técnicos, logo, possuem competência para criticarem os resultados, comparando com seus conhecimentos.

Já o grupo controle, embora traga uma simetria em seus dados com variação mínima entre os profissionais experientes (7,33) e não experientes (7,27), de forma isolada, vemos que é um grupo com maior dominância, comparada ao de tratamento,

sendo ela predominada nos profissionais experientes, o que pode se justificar pelo fato de perceberem no retorno da ferramenta um valor agregado diferente na sua rotina, já que pela celeridade e proximidade da classificação mais correta dada pela ferramenta, conseguirão dedicar mais tempo à análises mais estratégicas, por exemplo.

Com relação à variável especialização os profissionais do grupo controle confirmam nossa H2, visto que os que não possuem especialização na área confiam mais na devolutiva da ferramenta com IA do que os que possuem especialização, 7,34 x 7,28, respectivamente. Já o grupo tratamento rejeita nossa H2, visto que a dominância (confiança) prevalece nos profissionais que tem mais especialização.

Por fim, respondendo à pergunta desta pesquisa, foi possível, estatisticamente, identificar de que há impacto da alta familiaridade em relação à confiança (dominância) do profissional quando do uso de uma ferramenta com IA em rotinas tributárias e por meio da estatística descritiva da *survey*, temos que os profissionais brasileiros estão mais adeptos à tecnologia, quando comparada com um tempo atrás. Isto posto, há uma sinalização de que os profissionais veem a tecnologia como uma ferramenta de ajuda diante das burocráticas legislações e requerimentos do fisco, de forma que o *mindset* dos profissionais e a cultura das empresas vem mudando em relação à tecnologia, pois entendem que uma robotização ou aplicação de IA nos processos transacionais, libera horas para serem aplicadas em análises críticas e estratégicas, agregando valor nos resultados gerenciais e tomadas de decisão, logo, o uso de tecnologia, como IA, também indica que a gestão tributária é aprimorada.

Em relação à academia, vemos, também, já uma movimentação em relação à tecnologia, como a metodologia das salas invertidas, onde o aluno já aprende por meio de uma tecnologia ou IA, mas ainda há um longo caminho a ser percorrido até a grade da graduação em contabilidade ser ajustada e ter matérias relacionadas à tecnologia, IA, *data mining* e *warehouse*, por exemplo. Tema este que pode ser estudado futuramente, questionando em qual momento a academia estará pronta para esta mudança cultural nos currículos acadêmicos para a grade de contabilidade, em específico.

Em se tratando de temas futuros a serem pesquisados, ainda relacionados à esta pesquisa e considerando o perfil técnico dos profissionais que, inclusive, na *survey* ficou evidenciado, já que mais de 70% acertaram as três questões técnicas, inclusive uma delas com alta complexidade, relacionadas à PIS e COFINS, sugerimos

pesquisar se com o uso da tecnologia ou o aprimoramento dela, o profissional tributário ficará menos preparado tecnicamente, como, também pesquisar se um profissional iniciante ou experiente altera a condição de familiaridade e dominância e entender se profissionais experientes demandam mais tempo com análises de uma orientação dada por uma ferramenta com tecnologia, desafiando o *status quo*, do que os menos experientes.

## Referências

- Abbott, R., & Bogenschneider, B. (2018). Should Robots Pay Taxes: Tax Policy in the Age of Automation. *Harvard Law & Policy Review*, 12, 145. Retrieved from: <https://heinonline.org/HOL/LandingPage?handle=hein.journals/harlpolv12&div=10&id=&page=>
- Anzilago, M., Bernd, D. C., & Voese, S. B. (2014). Análise das competências e habilidades dos profissionais de Contabilidade na região de Curitiba/PR. *Revista ADMpg Gestão Estratégica*, 7(2), 73-81.
- Arnold, V., & Sutton, S. G. (1998). The theory of technology dominance: Understanding the impact of intelligent decision aids on decision maker's judgments. *Advances in accounting behavioral research*, 1(3), 175-194.
- Arnold, V. (2018). The changing technological environment & the future of behavioral research in accounting. *Accounting & Finance*, 58(2), 315-339.
- Arnold, V., P. A. Collier, S. A. Leech, & S. G. Sutton (2004). Impact of intelligent decision aids on expert and novice decision-makers' judgments. *Accounting & Finance*, 44(1), 1–26.
- Ashton, R. H. (1990). Pressure & performance in accounting decision settings: Paradoxical effects of incentives, feedback, & justification. *Journal of Accounting Research*, 28, 148–180.
- Askary, S., Abu-Ghazaleh, N., & Tahat, Y. A. (2018, October). Artificial Intelligence & Reliability of Accounting Information. *In Conference on e-Business, e-Services & e-Society* (pp. 315-324). Springer, Cham.
- Axelsen, M. (2012). Continued use of intelligent decision aids & auditor knowledge: qualitative evidence. *Accounting Information Systems (SIGASYS)*, 19. Retrieved from <https://aisel.aisnet.org/amcis2012/proceedings/AccountingInformationSystems/19/>
- Barros, V. D. M. (2005). O novo velho enfoque da informação contábil. *Revista Contabilidade & Finanças*, 16(38), 102-112.
- Blouch, W. E., Ulrich, T. A., & Michenzi, A. R. (2010). Enhancing student nontechnical professional business skills: An Academic Based Socialization Program. In *ASBBS 2010 ANNUAL CONFERENCE. Proceedings....* Pp. 320-333.
- Boatsman, J. R., Moeckel, C., & Pei, B. K. W. (1997). The effects of decision consequences on auditors' reliance on decision aids in audit planning. *Organizational Behavior & Human Decision Processes*, 71(2), 211–247.
- Bonaccio, S., & Dalal, R. S. (2006). Advice taking & decision-making: An integrative literature review, and implications for the organizational sciences. *Organizational Behavior & Human Decision Processes*, 101(2), 127–151.

- Bonavides, B. H. (2011). *Gerencia De Impostos - Ipi, Icms, Iss E Ir*. São Paulo: Atlas
- Brynjolfsson, E., & McAfee, A. (2014). *The second machine age: Work, progress, & prosperity in a time of brilliant technologies*. New York: WW Norton & Company. Retrieved from: [https://edisciplinas.usp.br/pluginfile.php/4312922/mod\\_resource/content/2/Erik%20-%20The%20Second%20Machine%20Age.pdf](https://edisciplinas.usp.br/pluginfile.php/4312922/mod_resource/content/2/Erik%20-%20The%20Second%20Machine%20Age.pdf)
- Campbell, D. T. (1957). Factors relevant to the validity of experiments in social settings. *Psychological Bulletin*, 54(4), 2917-312.
- Campbell, D. T. (1979). *Delineamentos experimentais e quase experimentais de pesquisa*. São Paulo: EPU-EDUSP.
- Cervo, A. L., Bervian, P.A., & Silva, R. (2002). *Metodologia científica* (6ª ed.). São Paulo: Pearson Prentice Hall.
- Cilliers, L. (2017). Wiki acceptance by university students to improve collaboration in higher education. *Innovations in Education and Teaching International*, 54(5), 485-493.
- Chase, M. D., & Shim, J. K. (1991). Artificial intelligence & big six accounting: A survey of the current uses of expert systems in the modern accounting environment. *Computers & industrial engineering*, 21(1-4), 205-209.
- Cordeiro, A., & Klann, R. C. (2015). Institucionalização de hábitos e rotinas com a implantação do Sistema Público de Escrituração Digital (SPED): Um estudo em organizações de serviços contábeis. *Revista Gestão Organizacional*, 7(1), 80-93
- Collis, J., & Hussey, R. (2005). *Pesquisa em administração: Um guia prático para alunos de graduação e pós-graduação*. Porto Alegre: Bookman.
- Conselho Federal de Contabilidade (CFC) (2019)
- Felipe, B. F. C., & Perrota, R. P. C. (2018). Inteligência Artificial no Direito—uma realidade a ser desbravada. *Revista de Direito, Governança e Novas Tecnologias*, 4(1), 1-16.
- Decreto 6.022, de 22 de janeiro de 2007*. Institui o Sistema Público de Escrituração Digital – Sped. Recuperado de [http://www.planalto.gov.br/ccivil\\_03/ Ato2007-2010/2007/Decreto/D6022.htm](http://www.planalto.gov.br/ccivil_03/ Ato2007-2010/2007/Decreto/D6022.htm)
- Didimo, W., Giamminonni, L., Liotta, G., Montecchiani, F., & Pagliuca, D. (2018). A visual analytics system to support tax evasion discovery. *Decision Support Systems*, 110, 71-83.
- Diniz, E. H., Barbosa, A. F., Junqueira, A. R. B., & Prado, O. (2009). O governo eletrônico no Brasil: perspectiva histórica a partir de um modelo estruturado de análise. *Revista de Administração Pública*, 43(1), 23-48. Recuperado de [https://www.scielo.br/scielo.php?pid=S0034-76122009000100003&script=sci\\_arttext&tlng=pt](https://www.scielo.br/scielo.php?pid=S0034-76122009000100003&script=sci_arttext&tlng=pt)

- Dowling, C., Leech, S. A., & Moroney, R. (2008). Audit support system design and the declarative knowledge of long-term users. *Journal of Emerging Technologies in Accounting*, 5(1), 99–108.
- Esnoide, A. L., Galo, M. F., Parisi, C., & Pereira, C. A. (2009). *Percepção dos controllers em relação à gestão tributária*. In *Congresso USP de Controladoria e Finanças*, São Paulo, São Paulo, Brasil, 9. Recuperado de <http://blog-fipecafi.imprensa.ws/wp-content/uploads/2012/01/A-RELA%C3%87%C3%83O-DOS-CONTROLLERS-COM-A-GEST%C3%83O-TRIBUT%C3%81RIA.pdf>
- Floridi, L. (2017). Robots, jobs, taxes, & responsibilities. *Philosophy & Technology*, 30(1), 1-4.
- Frawley, W. J., Piatetsky-Shapiro, G., & Matheus, C. J. (1992). Knowledge discovery in databases: An overview. *AI Magazine*, 13, 57–70.
- Furlan, P. K., & Laurindo, F. J. B. (2017). Agrupamentos epistemológicos de artigos publicados sobre big data analytics. *Transinformação*, 29(1), 91-100.
- Gall, M. D., Borg, W. R., & Gall, J. P. (1996). *Educational research: An introduction*. Longman Publishing.
- Geron, C. M. S., Finatelli, J. R., Faria, A. C. de, & Carmo Romeiro, M. do, (2011). SPED–Sistema Público de Escrituração Digital: Percepção dos contribuintes em relação os impactos de sua adoção. *Revista de Educação e Pesquisa em Contabilidade (REPeC)*, 5(2), 44-67.
- Ghahramani, Z. (2015). Probabilistic machine learning & artificial intelligence. *Nature*, 521(7553), 452 - 459.
- González, P. C., & Velásquez, J. D. (2013). Characterization & detection of taxpayers with false invoices using data mining techniques. *Expert Systems with Applications*, 40(5), 1427-1436.
- Göranzon, B., & Josefson, I. (Eds.). (2012). *Knowledge, skill and artificial intelligence*. London: Springer Science & Business Media.
- Grupe, F. H., & Owrang, M. M. (1995). Data base mining discovering new knowledge & cooperative advantage. *Informations Systems Management*, 12, 26–31.
- Guerra, F. M., & Gouveia, L. B. (2018). Política tecnológica de combate a sonegação fiscal e seus reflexos nos processos das empresas. *Revista de Contabilidade e Gestão Contemporânea*, 1(1), 30-41.
- Hageman, M. A. (2010). The role of confidence in tax return preparation using tax software. *Advances in Accounting Behavioral Research*, 13, 31–57.
- Hand, D. J. (1998). Data mining: Statistics and more? *The American Statistician*, 52(2), 112-118.
- Hand, D. J. (1999). Statistics and data mining: Intersecting disciplines. *SIGKDD Explorations*, 1(1), 16-19.

- Hampton, C. (2005). Determinants of reliance: An empirical test of the theory of technology dominance. *International Journal of Accounting Information Systems*, 6(4), 217–240.
- Hemberg, E., Rosen, J., Warner, G., Wijesinghe, S., & O'Reilly, U. M. (2016). Detecting tax evasion: A co-evolutionary approach. *Artificial Intelligence & Law*, 24(2), 149-182.
- Holland, P.W. (1986). Statistics and causal inference. *Journal of the American Statistical Association.*, 81(396), 945-960.
- Instituto Data Corporation. (2018). *Impacto Socioeconômico da Tributação Digital no Setor Público*. São Paulo: Autor. Recuperado de: <http://www.decisionreport.com.br/servicos/sistemas-tributarios-podem-tornar-se-mais-eficientes-com-ia-e-nuvem/#.XrRBAqhKjIU>.
- Instituto Brasileiro de Planejamento e tributação. (2017). *Edição de normas*. São Paulo: Autor. Recuperado em <https://ibpt.com.br/noticia/2603/Brasil-edita-cerca-de-800-normas-por-dia-somando-5-4-milhoes-desde-a-Constituicao-de-1988>
- Issa, H., Sun, T., & Vasarhelyi, M. A. (2016). Research ideas for artificial intelligence in auditing: The formalization of audit & workforce supplementation. *Journal of Emerging Technologies in Accounting*, 13(2), 1-20.
- Jensen, M. L., Lowry, P. B., Burgoon, J. K., & Nunamaker, J. F., Jr., (2010). Technology dominance in complex decision-making: The case of aided credibility assessment. *Journal of Management Information Systems*, 27(1), 175–201.
- Jones, S. H., & Wright, M. E. (2010). The effects of a hypertext learning aid and cognitive style on performance in advanced financial accounting. *Issues in Accounting Education*, 25(1), 35–58.
- Jordão, R. V. D., Silva, M. S., Vasconcelos, M. C. R. L., & Brasil, H. G. (2018). Inovações Organizacionais e de Negócios Trazidas pelo SPED: Um estudo empírico sobre as perspectivas de contadores e órgãos fiscalizadores. *Revista de Administração da Universidade Federal de Santa Maria*, 11(4), 942-960.
- Kasper, G. M. (1996). A theory of decision support system design for user calibration. *Information Systems Research*, 7(2), 137-277.
- Kokina, J., & Davenport, T. H. (2017). The emergence of artificial intelligence: How automation is changing auditing. *Journal of Emerging Technologies in Accounting*, 14(1), 115-122.
- Kolbjørnsrud, V., Amico, R., & Thomas, R. J. (2017). Partnering with AI: how organizations can win over skeptical managers. *Strategy & Leadership*, 45(1), 37-43.
- Krahel, J. P., & Titera, W. R. (2015). Consequences of Big Data & formalization on accounting & auditing standards. *Accounting Horizons*, 29(2), 409-422.



- KPMG (2016). *Harnessing the power of cognitive technology to transform the audit*. Retrieved from: [pdfs/2016/cognitive-technology-transform-audit.pdf](#)
- Leão, C. F., Isatto, E. L. & Formoso, C.T. (2016). Proposta de modelo para controle integrado da produção e da qualidade com apoio da computação móvel. *Ambient. constr.* [online]. 16(4), 109-124. Recuperado de [https://www.scielo.br/scielo.php?pid=S1678-86212016000400109&script=sci\\_arttext](https://www.scielo.br/scielo.php?pid=S1678-86212016000400109&script=sci_arttext)
- Llacer, T., Miguel, F. J., Noguera, J. A., & Tapia, E. (2013). An agent-based model of tax compliance: an application to the Spanish case. *Advances in Complex Systems*, 16(4-5). Doi: <https://doi.org/10.1142/S0219525913500070>
- Luft, J., & Shields, M. D. (2003). Mapping management accounting: graphics and guidelines for theory-consistent empirical research. *Accounting, organizations and society*, 28(2-3), 169-249.
- Macarini, A. J., Fº, Ferreira, A. C. L. D., Xavier, E. C., & Carvalho, D. R. (2017). Mineração de dados no fluxo de processos que impactam na arrecadação tributária em Curitiba. *Revista Stricto Sensu*, 2(2), 29-38.
- Mackey, J. M., & Elam, J. J. (1992). A comparative study of how experts & novices use a decision aid to solve problems in complex knowledge domains. *Information Systems Research*, 3(2), 99-190.
- Mălăescu, I., & Sutton, S. G. (2015). The effects of decision aid structural restrictiveness on cognitive load, perceived usefulness, and reuse intentions. *International Journal of Accounting Information Systems*, 17, 16-36.
- Marar, J. F., Carvalho, E. C., Fº, & Vasconcelos, G. C. (1996, March). Function approximation by polynomial wavelets generated from powers of sigmoids. In *Wavelet Applications III* (Vol. 2762, pp. 365-375). *International Society for Optics & Photonics*.
- Marshall, T. E., & Lambert, S. L. (2018). Cloud-based intelligent accounting applications: Accounting task automation using IBM watson cognitive computing. *Journal of Emerging Technologies in Accounting*, 15(1), 199-215.
- Martins, K., Schlemper, S., Schutz, T. C., & Braun, A. L. (2018). Sistema público de escrituração digital (SPED): Como as principais universidades da grande Florianópolis estão preparando os acadêmicos para a era digital da contabilidade? *Revista UNEMAT de Contabilidade*, 7(13), 22-36.
- Martins, G. D. A., & Theóphilo, C. R. (2009). *Metodologia da investigação científica*. São Paulo: Atlas.
- Mascha, M. F., & Smedley, G. (2007). Can computerized decision aids do “damage?” A case for tailoring feedback and task complexity based on task experience. *International Journal of Accounting Information Systems*, 8(2), 73–91.

- Masselli, J. J., R. C. Ricketts, V. Arnold, & S. G. Sutton (2002). The impact of embedded intelligent agents on tax-reporting decisions. *The Journal of the American Taxation Association*, 24(2), 60–78.
- McCarty, L. T. (1976). Reflections on Taxman: An experiment in artificial intelligence & legal reasoning. *Harvard Law Review*, 90(5), 837.
- McFarlan, F. W., McKenney, J. L., & Pyburn, P. (1983). The information archipelago--plotting a course. *Harvard business review*, 61(1), 145-156.
- Mello, K. D. (2013). Habilidades e competências do profissional contábil: Um estudo do perfil requerido em Caxias do Sul. (Dissertação). Universidade Caxias do Sul, SC, Brasil.
- Siqueira, N. A. S. (2002). Substituição da força de venda própria por distribuidores: Um estudo de caso (Dissertação de Mestrado). Fundação Escola de Comércio Álvares Penteado - FECAP, São Paulo, SP, Brasil
- Meservy, R. D., Denna, E. L., & Hansen, J. V. (1992). Application of artificial intelligence to accounting, tax, & audit services: Research at Brigham Young University. *Expert Systems with Applications*, 4(2), 213-218.
- Linoff, G. S., & Berry, M. J. (2011). *Data mining techniques: For marketing, sales, and customer relationship management*. John Wiley & Sons.
- Miller, A. H. (2019, February). Data modeling & visualization of tax strategies employed by overseas American individuals & firms. In *International Conference on Emerging Internetworking, Data & Web Technologies* (pp. 309-321). Springer, Cham.
- Minsky, M. (1961). Steps toward artificial intelligence. *Proceedings of the IRE*, 49(1), 8-30.
- Miyoshi, R. K., & Nakao, S. H. (2012). Riscos de conformidade tributária: Um estudo de caso no estado de São Paulo. *Revista de Contabilidade e Organizações*, 6(14), 46-76.
- Nazareth, L. G. C. (2018) Controladoria tributária: Uma contribuição para a sua estrutura conceitual (Tese de Doutorado). Universidade Metodista de Piracicaba. Piracicaba, SP, Brasil.
- Noga, T., & V. Arnold (2002). Do tax decision support systems affect the accuracy of tax compliance decisions? *International Journal of Accounting Information Systems*, 3(3), 125–144.
- Nycz, M., & Smok, B. (2006). Data warehouse – The source of business information. In *Proceedings of the 2006 information science & IT education Joint Conference* (pp. 243–250). Salford, UK.
- Ordem dos Advogados do Brasil (AOB) (2019)

- O'leary, D. E. (1991). Artificial intelligence & expert systems in accounting databases: Survey & extensions. *Expert Systems with Applications*, 3(1), 143-152.
- O'Leary, D. E., & O'Keefe, R. M. (1997). The impact of artificial intelligence in accounting work: Expert systems use in auditing & tax. *Ai & Society*, 11(1-2), 36-47.
- Oliveira, G. P. (2009). *Contabilidade tributária* (3a ed.). São Paulo: Saraiva.
- Organização para a Cooperação e Desenvolvimento Econômico. (2018). *Relatórios Econômicos*. São Paulo: Autor. Recuperado em <http://www.oecd.org/economy/surveys/Brazil-2018-OECD-economic-survey-overview-Portuguese.pdf>.
- Passos, L. C. (2011). *Raciocínio crítico de estudantes de graduação em ciências contábeis: Aplicação do modelo institucional de Richard Paul* (Tese de Doutorado). Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, São Paulo, SP, Brasil.
- Peleias, I. R., Guimarães, P. C., Da Silva, D. & De Ornelas, M. M. G. (2008). Identificação do perfil profissiográfico do profissional de contabilidade requerido pelas empresas, em anúncios de emprego na região metropolitana de São Paulo. *Revista Base (Administração e Contabilidade) da UNISINOS*, 5(2), 131-141.
- Peterson D, & Pitz G. (1986). Effects of input from a mechanical model on clinical judgment. *Journal of Applied Psychology*, 71(1);163– 167.
- Perrow, C. (1967). A framework for the comparative analysis of organisations, *American Sociological Review*, 32(2), 194–208.
- Pires, C. B., Ott, E., & Damacena, C. (2009). “Guarda-Livros” ou “Parceiros de Negócios”? Uma análise do perfil profissional requerido pelo mercado de trabalho para contadores na Região Metropolitana de Porto Alegre (RMPA). *Contabilidade Vista & Revista*, 20(3), 157-187. 169-249.
- Porto, É. G. (2017). A busca pela eficiência na fiscalização da gestão pública: A utilização da inteligência ar para aperfeiçoamento do controle das finanças públicas. *Revista de Direito da Empresa e dos Negócios*, 1(2), 4-31.
- Prado, E. C. P. (2015). O papel e a atuação do contador tributário. *Revista de Ciências Gerenciais*, 17(26), 131-143.
- Recht, M., & Bryan, R. N. (2017). Artificial intelligence: Threat or boon to radiologists?. *Journal of the American College of Radiology*, 14(11), 1476-1480.
- Rocha, L. F., & Silva, M. A. da (2019). Empregabilidade no setor contábil, modalidade de formação acadêmica e gênero: Qual a relação?. *Revista Catarinense da Ciência Contábil*, 18, 1-16.

- Rose, J. (2002). Behavioral decision aid research: Decision aid use & effects. In V. Arnold, & S. Sutton (Eds.). *Researching Accounting as an Information Systems Discipline* (pp. 111–134). Sarasota, FL: American Accounting Association.
- Russell, S. J., & Norvig, P. (2016). *Artificial intelligence: A modern approach*. Malaysia: Pearson Education Limited.
- Santos, D. F., Sobral, F. S., Correa, M. D., Antonovz, T., & Santos, R. F. (2011). Perfil do profissional contábil: Estudo comparativo entre as exigências do mercado de trabalho e a formação oferecida pelas instituições de ensino superior de Curitiba. *Revista Contemporânea de Contabilidade*, 8(16), 137-152.
- Silva, C. M. M., Da Silva, L. F. F., & Drumond, F. M. M. P. (2015). Obrigações Acessórias: O papel do profissional contábil na implantação do sped fiscal em grupo de empresa do setor siderúrgico. *Ric: Revista de Informação Contábil*, 9(4), 42-60.
- Souza, M. C. D. (2014). *O uso de inteligência artificial no ensino de contabilidade* (Tese de doutorado). Universidade de São Paulo, São Paulo, SP, Brasil.
- Sun, T., & Vasarhelyi, M. A. (2018). Embracing textual data analytics in auditing with deep learning. *The International Journal of Digital Accounting Research*, 18, 49-67.
- Sutton, S. G., Holt, M., & Arnold, V. (2016). The reports of my death are greatly exaggerated—Artificial intelligence research in accounting. *International Journal of Accounting Information Systems*, 22, 60-73.
- Tabandeh, R., Jusoh, M., Nor, N. G. M., & Zaidi, M. A. S. (2012). Estimating factors affecting tax evasion in Malaysia: A neural network method analysis. *Persidangan Kebangsaan Ekonomi Malaysia ke VII (PERKEM VII)*, Transformasi Ekonomi dan Sosial Ke Arah Negara Maju, Ipoh, Perak, 4-6.
- Tamer, C., Viana, C., Soares, L. A., & Lima, M. (2013). Perfil do profissional contábil demandado pelo mercado de trabalho: Um estudo no norte do Brasil. *Revista Universo Contábil*, 9(3), 143-162.
- Taylor S, & Todd P. (1995). Assessing IT usage: The role of prior experience. *MIS Quarterly*, 19(4), 561– 570.
- Trikki, A., & Weisner, M. M. (2014), Lessons from the literature on the theory of technology dominance: Possibilities for an extended research framework. *Journal of Emerging Technologies in Accounting*, 11(1), 41-69.
- Turing, A. M. (1937). On computable numbers, with an application to the Entscheidungsproblem. *Proceedings of the London mathematical society*, 2(1), 230-265
- Todd P, & Benbasat I. (1999). Evaluating the impact of DSS, cognitive effort, & incentives on strategy selection. *Information Systems Research*, 10(4), 356–374.

- Trikki, A., & Weisner, M. M. (2014), Lessons from the literature on the theory of technology dominance: Possibilities for an extended research framework. *Journal of Emerging Technologies in Accounting*, 11(1), 41-69.
- Yang, J. C., Chuang, H. C., & Kuan, C. M. (2019). Double machine learning with gradient boosting & its application to the big n audit quality effect. *USC-INET Research Paper* N.19-05. Recuperado de [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3351314](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3351314)
- Warner, G., Wijesinghe, S., Marques, U., Badar, O., Rosen, J., Hemberg, E., ... & O'Reilly, U. M. (2015). Modeling tax evasion with genetic algorithms. *Economics of Governance*, 16(2), 165-178.
- Whitecotton, S. M. (1996). The effects of experience & confidence on decision aid reliance: A causal model. *Behavioral Research in Accounting*, 8, 194–216.
- Whitecotton S, & Butler S. (1998). Influencing decision aid reliance through involvement in information choice. *Behavioral Research in Accounting*, 10, 182–200 [Supplement].
- Williamson, O. (1985). *The economic institutions of capitalism: Firms, markets, relational contracting*. Nova Iorque: The Free Press
- World Bank Group, & PricewaterhouseCoopers. (2018). *Paying Taxes 2018*. Netherlands. Recuperado de [https://www.pwc.com/gx/en/paying-taxes/pdf/pwc\\_paying\\_taxes\\_2018\\_full\\_report.pdf](https://www.pwc.com/gx/en/paying-taxes/pdf/pwc_paying_taxes_2018_full_report.pdf)
- Wu, R. S., Ou, C. S., Lin, H. Y., Chang, S. I., & Yen, D. C. (2012). Using data mining technique to enhance tax evasion detection performance. *Expert Systems with Applications*, 39(10), 8769-8777.

## **Apêndice A – Termo de Consentimento Livre e Esclarecido**

### **TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO**

Concordo em participar, como voluntário, do estudo intitulado: Estudo sobre a Teoria da Dominância Tecnológica no uso da Inteligência Artificial aplicada à Gestão Tributária no Brasil.

O estudo é coordenado pelos pesquisadores Jailson Evangelista (evangelista.jailson@edu.fecap.br) e Prof. Dr. Tiago Slavov (tiago.slavov@fecap.br). Este estudo conta ainda com o apoio dos professores Prof. Dr. Matheus Albergaria (FECAP), Prof. Dr. Luis Borges Gouveia (Univ. Fernando Pessoa - Portugal) e Prof. Fabio Rodrigues de Oliveira (BSSP). Os coordenadores supracitados podem ser contatados pelos e-mails informados.

O presente trabalho tem como objetivo investigar os efeitos da IA sobre a formação, experiência e qualidade das decisões tomadas pelos profissionais tributários brasileiros, sob a ótica da Theory of Technology Dominance, teoria desenvolvida pela Profa. Vicky Arnold (University of Central Florida)

A minha participação consistirá em:

- 1) Utilizar o sistema de Inteligência Artificial Busca.Legal (T2), realizando consultas e testes, antes do preenchimento do presente questionário;
- 2) Ao final das consultas e testes, participar da pesquisa relatando as minhas percepções sobre o impacto da Inteligência Artificial na minha formação, experiência e decisões tomadas.

Compreendo que este estudo possui finalidade de pesquisa, portanto não receberei nenhum tipo de remuneração, que os dados obtidos serão confidenciais e serão divulgados seguindo as diretrizes éticas de pesquisa, não havendo identificação dos voluntários, a não ser entre os responsáveis pelo estudo, sendo assegurado o sigilo, anonimato e privacidade sobre a minha participação.

Tenho garantido o direito de não aceitar participar da pesquisa e ainda, durante todo o período, tenho garantido o direito de retirar a minha permissão, a qualquer momento, sem nenhum tipo de prejuízo ou retaliação pela minha decisão.

## Apêndice B - Instrumentos de Coleta de Dados

### Apresentação

Este questionário integra um projeto de mestrado que visa a utilização de novas tecnologias, como a Inteligência Artificial, na rotina do profissional da área tributária e, assim, medir a confiança creditada nas informações recebidas para a tomada de decisão, de forma que sua participação é essencial!

### Parte I: Coleta de dados

#### Dados Pessoais

##### 1) Sexo:

- Masculino
- Feminino

##### 2) Idade:

- Entre 18 e 25
- Entre 26 e 35
- Entre 36 e 45
- Entre 46 e 55
- Acima de 55

##### 3) Região em que mora:

- Sul
- Sudeste
- Centro-Oeste
- Norte
- Nordeste

##### 4) Cargo Atual:

- Assistente Fiscal
- Auxiliar Fiscal
- Analista Fiscal

- ( ) Especialista Fiscal  
 ( ) Coordenador Fiscal  
 ( ) Supervisor Fiscal  
 ( ) Gerente Fiscal  
 ( ) Outro

5) Se você selecionou a opção "outro" na questão anterior, por favor, informe qual seria:

### 6) Formação

Formação	Contábeis	Direito	Administração	Tecnologia	Nenhum	Outra
Graduação						
Especialização						
Mestrado						
Doutorado						

7) Se você selecionou a opção "outro" na questão acima, por favor, se desejar, informe sua formação:

### 8) Experiência

(Considere -1 para menos de 12 meses, 1 e 2 para entre 1 e 2 anos e assim sucessivamente)

Questões	Anos					
	Menos de 1 ano	Entre 1 e 2 anos	Entre 3 e 4 anos	Entre 5 e 6 anos	Entre 7 e 8 anos	9 anos ou mais
Tempo de atuação na área tributária ("em anos")	-1	1	2	3	4	5
Tempo de atuação no cargo atual ("em anos")	-1	1	2	3	4	5
Tempo de atuação com tributos indiretos ("em anos")	-1	1	2	3	4	5
Tempo de atuação com análise da tributação sobre produtos ("em anos")	-1	1	2	3	4	5

### 9) Familiaridade com Tecnologias em geral

- a) Os recursos tecnológicos que utilizo no meu dia a dia são úteis ( ) Sim ( ) Não  
 b) Me sinto confortável com o uso das modernas tecnologias ( ) Sim ( ) Não  
 c) Me sinto confortável com o uso das decisões baseadas em inteligência artificial ( ) Sim ( ) Não



- d) Pretendo utilizar intensamente as decisões baseadas em inteligência artificial no futuro ( ) Sim ( ) Não
- e) Recomendo o uso de tecnologias e inteligência artificial na área tributária ( ) Sim ( ) Não ( )

**10) Percepção sobre a Inteligência Artificial:**

- e) O Busca.Legal reduziu o tempo da tarefa ( ) Sim ( ) Não
- f) O Busca.Legal aumentou a eficiência na resposta ( ) Sim ( ) Não
- g) O Busca.Legal tornou a resposta mais fáceis ( ) Sim ( ) Não
- h) O Busca.Legal mostrou-se útil na minha rotina diária ( ) Sim ( ) Não
- i) Pretendo usar o Busca.Legal nas próximas demandas ( ) Sim ( ) Não
- j) O desempenho alcançado pelo Busca.Legal foi superior ao meu desempenho técnico e manual ( ) Sim ( ) Não
- k) O Busca.Legal reduziu a necessidade de análises técnicas e estratégica ( ) Sim ( ) Não
- l) Recomendo a Inteligência Artificial do Busca.Legal para rotinas de classificação tributária dos produtos ou mercadorias ( ) Sim ( ) Não

**11) Foi seu primeiro acesso ao Busca.Legal?**

- ( ) Sim
- ( ) Não

**Parte II: Relatos**

**12) A solicitação de análise de tributação sobre produtos ou mercadorias é recorrente em seu dia a dia?**

- ( ) Sim
- ( ) Não

**13) Relate sua maior dificuldade com relação à análise de tributação sobre produtos ou mercadorias:**

- ( ) Busca pela legislação

- ( ) Interpretação da legislação
- ( ) Interpretação do texto descritivo do produto
- ( ) Quantidade de impostos incidentes sobre um produto

**14)** Se sua maior dificuldade não está listada acima, informe qual seria:

**15)** Qual o grau de participação da tecnologia, em suas análises, quando se trata de tributação sobre produtos ou mercadorias?

- ( ) Alta
- ( ) Média
- ( ) Baixa
- ( ) Nenhuma

**16)** Relate avaliações positivas em relação à alguma performance da sua rotina fiscal:

- ( ) Participação em projetos relevantes
- ( ) Reconhecimentos da liderança
- ( ) Promoções
- ( ) Movimentação lateral
- ( ) Nenhuma
- ( ) Outra

**17)** Se as opções listadas acima, não representam o que lhe ocorreu, por favor, descreva suas avaliações positivas de performance:

**18)** Relate, avaliações negativas, em relação à alguma performance da sua rotina fiscal:

- ( ) Desligamento
- ( ) Tarefa Incompleta
- ( ) Perca de oportunidades (promoções, movimentações laterais)
- ( ) Nenhuma

**19)** Se as opções de avaliação negativa, não representam o que ocorreu, por favor, relate as avaliações recebidas:

**20) Estas avaliações tiveram alguma relação com uso de tecnologia?**

*(considere 1 para discordo totalmente, 2 e 3 para discordo parcialmente, 4 para nem discordo e nem concordo, 5 e 6 para concordo parcialmente e 7 para concordo totalmente)*

Avaliações Positivas	1	2	3	4	5	6	7
Avaliações Negativas	1	2	3	4	5	6	7

**Parte III: Nivelamento Técnico**

**21)** Quais os regimes de tributação do PIS e da COFINS e suas alíquotas comuns?

- Regime Cumulativo (1,65% e 7,6%) e Regime Não Cumulativo (0,65% e 3%)
- Regime Cumulativo (1,65% e 7,6%)
- Regime Cumulativo (0,65% e 3%) e Regime Não Cumulativo (1,65% e 7,6%)
- Regime Não Cumulativo (0,65% e 3%)

**22)** É permitido a apropriação de crédito de PIS e COFINS em relação aos custos incorridos com armazenagens e fretes?

- Sim, mas somente de fretes e armazenagens relativos às vendas de insumos e mercadorias
- Sim, mas somente de fretes e armazenagens relativos às compras de insumos e mercadorias
- Não é permitido a apropriação destes créditos
- É permitido a apropriação destes créditos, inclusive sobre fretes e armazenagens nas operações de compras, isto é, desde que o ônus seja suportado pelo vendedor.

**23)** Açúcar mascavo (1kg) e açúcar de baunilha (1kg) possuem tributações diferentes no que se refere ao PIS e a COFINS?

- Sim, açúcar mascavo (1kg) é tributado à alíquota zero e açúcar de baunilha (1kg) tributado à alíquota básica
- Sim, açúcar mascavo (1kg) é tributado à alíquota básica e açúcar de baunilha (1kg) tributado à alíquota zero

- Não, ambos não são tributados
- Não, ambos são tributados à alíquota básica

**24)** Caso você tenha interesse em receber os resultados desta pesquisa, por favor, informe seu e-mail abaixo:

### Apêndice C – Gabarito das Questões Alternativas

**Questão 21** - Regime Cumulativo (0,65% e 3%) e Regime Não Cumulativo (1,65% e 7,6%).

**Questão 22** - Sim, é possível a apropriação destes créditos, conforme dispõe o artigo 3º, inciso IX, das Leis nº 10.833/2003 e 10.637/02, a qual legisla que do valor a pagar do PIS e da COFINS, a pessoa jurídica poderá descontar créditos dos custos incorridos relativos à armazenagem de mercadoria e frete na operação de venda e nos casos dos bens adquiridos para revenda e/ou utilizados como insumos, quando o ônus for suportado pelo comprador.

**Questão 23** - Sim, açúcar mascavo (1kg) é tributado à alíquota zero, conforme disposto no artigo 1º, XXII, da Lei 19.925/04 e açúcar de baunilha (1kg) é tributado à alíquota básica, conforme disposto no artigo 1º e 2º das Leis 10.833/03 e 10.637/02.